Prof. Dr. Hendrik Godbersen

Kurs

Angewandte Statistik & R

Inhalt

1 Einleitung

2 Installation & Grundstruktur von R Studio

2.1 Installation von R, R Studio & relevanten Paketen

2.2 Grundstruktur von R Studio

3 R-Befehle & Übungsdaten

3.1 R-Befehle

3.2 Übungsdaten

4 Datenmanagement

4.1 Datenvorbereitung & Laden von Daten

4.2 Daten bearbeiten in R

5 Deskriptive Statistik

5.1 Skalenniveaus

5.2 Häufigkeiten

5.3 Lageparameter & Streuungsmaße

6 Inferenzstatistische Verfahren

6.1 Überblick & Systematisierung der Verfahren

6.2 Chi-Quadrat-Test

6.3 t-Test

6.4 ANOVA

6.5 Shapiro-Wilk-Test

6.6 Wilcoxon-Test

6.7 Korrelation

6.8 Regression

6.9 Hauptkomponentenanalyse

7 Graphiken & Export von Ergebnissen nach Excel

7.1 Graphiken in R

7.2 Export von Ergebnissen nach Excel

Einleitung

RStudio

Rworkshop_Radio2.R | radio | frame_Geschlecht

```
41  radio$SenderCluster2[radio$SenderCluster=="Privat jung"] <- "Privat"
42  radio$SenderCluster2[radio$SenderCluster=="Privat alt"] <- "Privat"
43  radio$SenderCluster2[radio$SenderCluster=="SWR"] <- "SWR"
44
45  radio$CoGe <- (radio$Comedy + radio$Gewinnspiele) / 2
46
47  radio_weiblich <- radio[radio$Geschlecht == "weiblich",]
48  View(radio_weiblich)
49
50
51  # Häufigkeiten, Lageparameter & Streuungsmasse
52  # Häufigkeiten
53  tally(~Geschlecht, data = radio)
54  tally(~Geschlecht, format = "proportion", data = radio)
55  tally(~Geschlecht, format = "percent", data = radio)
56
57  tally(~SenderCluster, format = "percent", data = radio)
58
59  tally(SenderCluster~Geschlecht, format = "percent", data = radio)
60
```

157:31 (Top Level) R Script

Environment | History | Connections

Global Environment

Data	
frame_Gesc…	2 obs. of 2 variables
radio	275 obs. of 26 variables
Values	
table_Gesc…	'table' num [1:2(1d)] 46.9 5…

Console

```
>
>
> # Setup
> require(mosaic)
> require(psy)
> require(psych)
> require(openxlsx)
> load("~/Desktop/Rworkshop/radio.RData")
> View(radio)
> # Häufigkeiten, Lageparameter & Streuungsmasse
> # Häufigkeiten
> tally(~Geschlecht, data = radio)
Geschlecht
maennlich  weiblich
      129       146
> # Graphiken - Häufigkeiten
```

Files | Plots | Packages | Help | Viewer

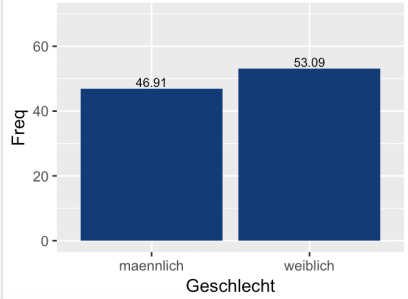

Einleitung

- **Dieser Kurs vermittelt das Wissen & die Fähigkeiten,…**
  - …die gängigen Verfahren der deskriptiven & inferenzstatistischen Auswertung zu verstehen und anzuwenden
  - …mit R zu arbeiten & die für statistische Auswertungen notwendigen Befehle anzuwenden
  - **…ein empirisches Projekt mit den „gängigen“ statistischen Verfahren in R auszuwerten**

- **Sie erhalten auf www.godbersen.online…**
  - …das Buch zu diesem Kurs zum strukturierten Lernen & Üben
  - das Befehlssammlung mit allen notwendigen R-Befehlen, um ein empirisches Projekt mit den „gängigen“ Verfahren auszuwerten
  - …einen „echten“ Datensatz, mit dem die Übungsaufgaben zu diesem Kurs realisiert werden

Inhalt

1 Einleitung
2 Installation & Grundstruktur von R Studio
3 R-Befehle & Übungsdaten
4 Datenmanagement
5 Deskriptive Statistik
6 Inferenzstatistische Verfahren
7 Graphiken & Export von Ergebnissen nach Excel

Einleitung

- **Kern des Kurses sind die statistischen Verfahren (Kap. 5 & 6):**
  1) Erklärung der statistischen Verfahren
  2) Übungsaufgabe mit einem „echten Datensatz“
  3) Umsetzung der statischen Analyse in R

- **Nutzung des Kurses für den größten Lernerfolg:**
  - Nutzung von Kurs, Buch & Videos:
    - Am Anfang: Kapitel-für-Kapitel & Schritt-für-Schritt
    - Später: Nachschlagewerk
  - Herangehensweise:
    - Wann wende ich welches Verfahren an & wie interpretieren ich die Ergebnisse? (& nicht: Wie programmiere ich mit R?)
  - Lernziel:
    - Expertise in anwendungs- & umsetzungsorientierter empirischer Forschung (& nicht in „abgedrehtem“ Statistikwissen)

Inhalt

1 Einleitung
2 Installation & Grundstruktur von R Studio
3 R-Befehle & Übungsdaten
4 Datenmanagement
5 Deskriptive Statistik
6 Inferenzstatistische Verfahren
7 Graphiken & Export von Ergebnissen nach Excel

Einleitung

RStudio

Rworkshop_Radio2.R | radio | frame_Geschlecht

```
41  radio$SenderCluster2[radio$SenderCluster=="Privat jung"] <- "Privat"
42  radio$SenderCluster2[radio$SenderCluster=="Privat alt"] <- "Privat"
43  radio$SenderCluster2[radio$SenderCluster=="SWR"] <- "SWR"
44
45  radio$CoGe <- (radio$Comedy + radio$Gewinnspiele) / 2
46
47  radio_weiblich <- radio[radio$Geschlecht == "weiblich",]
48  View(radio_weiblich)
49
50
51  # Häufigkeiten, Lageparameter & Streuungsmasse
52  # Häufigkeiten
53  tally(~Geschlecht, data = radio)
54  tally(~Geschlecht, format = "proportion", data = radio)
55  tally(~Geschlecht, format = "percent", data = radio)
56
57  tally(~SenderCluster, format = "percent", data = radio)
58
59  tally(SenderCluster~Geschlecht, format = "percent", data = radio)
60
```

157:31 (Top Level) R Script

Environment | History | Connections

Global Environment

Data	
frame_Gesc…	2 obs. of 2 variables
radio	275 obs. of 26 variables
Values	
table_Gesc…	'table' num [1:2(1d)] 46.9 5…

Console

```
>
>
> # Setup
> require(mosaic)
> require(psy)
> require(psych)
> require(openxlsx)
> load("~/Desktop/Rworkshop/radio.RData")
> View(radio)
> # Häufigkeiten, Lageparameter & Streuungsmasse
> # Häufigkeiten
> tally(~Geschlecht, data = radio)
Geschlecht
maennlich  weiblich
      129       146
> # Graphiken - Häufigkeiten
```

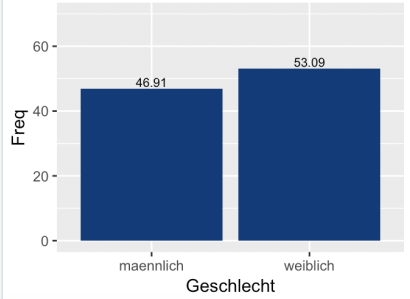

Inhalt

1 Einleitung
2 Installation & Grundstruktur von R Studio
2.1 Installation von R, R Studio & relevanten Paketen
2.2 Grundstruktur von R Studio
3 R-Befehle & Übungsdaten
3.1 R-Befehle
3.2 Übungsdaten
4 Datenmanagement
4.1 Datenvorbereitung & Laden von Daten
4.2 Daten bearbeiten in R
5 Deskriptive Statistik
5.1 Skalenniveaus
5.2 Häufigkeiten
5.3 Lageparameter & Streuungsmaße
6 Inferenzstatistische Verfahren
6.1 Überblick & Systematisierung der Verfahren
6.2 Chi-Quadrat-Test
6.3 t-Test
6.4 ANOVA
6.5 Shapiro-Wilk-Test
6.6 Wilcoxon-Test
6.7 Korrelation
6.8 Regression
6.9 Hauptkomponentenanalyse
7 Graphiken & Export von Ergebnissen nach Excel
7.1 Graphiken in R
7.2 Export von Ergebnissen nach Excel

Installation von R, R Studio & relevanten Zusatzpaketen

Prof. Dr.
Godbersen

1) **Download & Installation von R** (R ist das Basisprogramm)
   1) Gehen sie zu: https://www.r-project.org/
   2) Wählen Sie einen Mirror zum Download aus
      - ➢ Achten Sie darauf, dass Sie R passend zu Ihrem Betriebssystem wählen
   3) Laden Sie R herunter
   4) Installieren Sie R auf Ihrem Computer

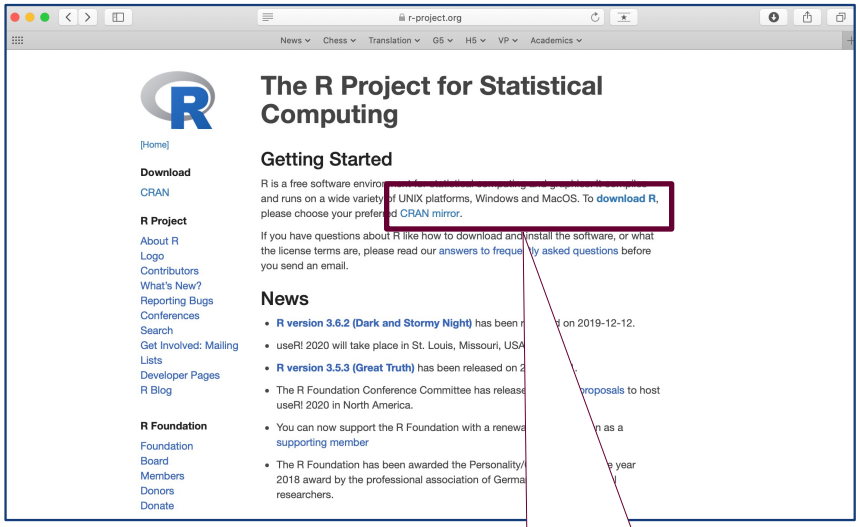

Zum Download von R auf www.r-project.org

2) **Download & Installation von R Studio** (R Studio ist eine Entwicklungsumgebung für R & Erleichtert die Bedienung)
   1) Gehen Sie zu: https://rstudio.com/products/rstudio/download/
   2) Laden Sie R Studio herunter
   3) Installieren Sie R auf Ihrem Computer

3) **Installieren Sie die Zusatzpakete in R Studio**

Installation von R, R Studio & relevanten Zusatzpaketen

1) Download & Installation von R ✓
2) Download & Installation von R Studio ✓
3) **Installieren Sie die Zusatzpakete in R Studio**
   1) Stellen Sie sicher, dass Ihr Computer mit dem Internet verbunden ist
   2) Geben Sie in die Console folgenden Befehl ein: install.packages("mosaic")
   3) Betätigen Sie die Return-Taste
   4) Wiederholen Sie dieses Vorgehen für alle relevanten Pakete

Benötigte R-Pakete:

- mosaic
- psych
- psy
- ggplot2
- openxlsx
- readxl

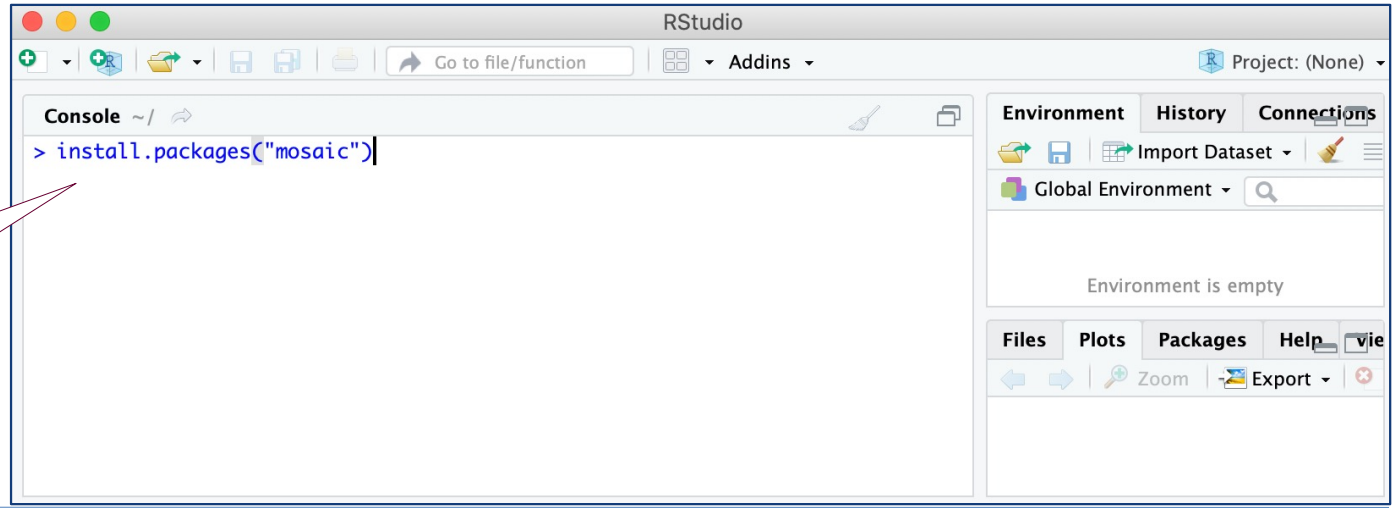

Befehl install.packages("mosaic") eingeben & Return-Taste betätigen

Inhalt

1 Einleitung
2 Installation & Grundstruktur von R Studio
2.1 Installation von R, R Studio & relevanten Paketen
2.2 Grundstruktur von R Studio
3 R-Befehle & Übungsdaten
3.1 R-Befehle
3.2 Übungsdaten
4 Datenmanagement
4.1 Datenvorbereitung & Laden von Daten
4.2 Daten bearbeiten in R
5 Deskriptive Statistik
5.1 Skalenniveaus
5.2 Häufigkeiten
5.3 Lageparameter & Streuungsmaße
6 Inferenzstatistische Verfahren
6.1 Überblick & Systematisierung der Verfahren
6.2 Chi-Quadrat-Test
6.3 t-Test
6.4 ANOVA
6.5 Shapiro-Wilk-Test
6.6 Wilcoxon-Test
6.7 Korrelation
6.8 Regression
6.9 Hauptkomponentenanalyse
7 Graphiken & Export von Ergebnissen nach Excel
7.1 Graphiken in R
7.2 Export von Ergebnissen nach Excel

Grundstruktur von R Studio

Script mit R-Befehlen

Öffnen, Speichern etc. von Dateien erfolgt wie bei anderen Programmen über das Menü

Anzeige des Datensatzes (Achtung: Anzeige ≠ geladener Datensatz)

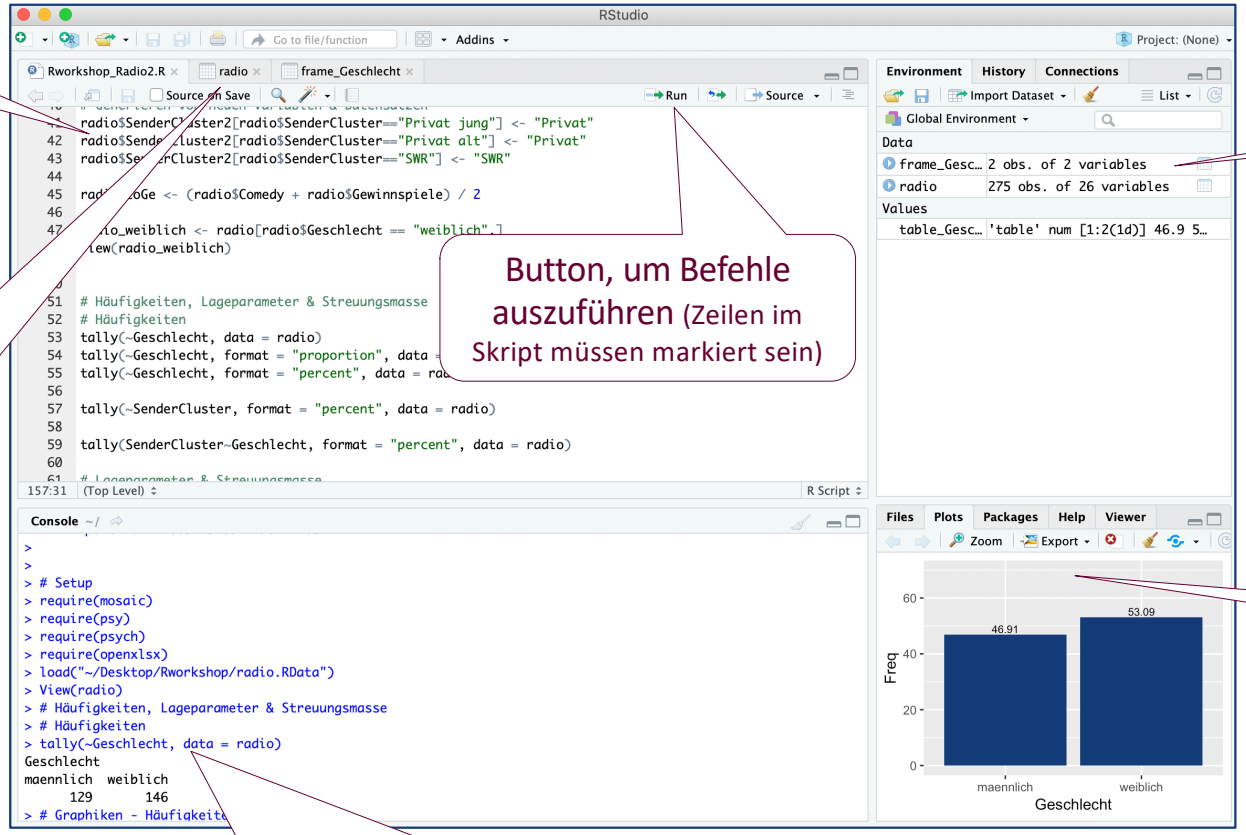

Button, um Befehle auszuführen (Zeilen im Skript müssen markiert sein)

Geladener Datensatz & generierte Objekte

Generierte Graphiken

Console mit Ergebnisse (Befehlseingabe auch hier möglich; Befehle werden aber nicht gespeichert)

Inhalt

1 Einleitung

2 Installation & Grundstruktur von R Studio

2.1 Installation von R, R Studio & relevanten Paketen

2.2 Grundstruktur von R Studio

3 R-Befehle & Übungsdaten

3.1 R-Befehle

3.2 Übungsdaten

4 Datenmanagement

4.1 Datenvorbereitung & Laden von Daten

4.2 Daten bearbeiten in R

5 Deskriptive Statistik

5.1 Skalenniveaus

5.2 Häufigkeiten

5.3 Lageparameter & Streuungsmaße

6 Inferenzstatistische Verfahren

6.1 Überblick & Systematisierung der Verfahren

6.2 Chi-Quadrat-Test

6.3 t-Test

6.4 ANOVA

6.5 Shapiro-Wilk-Test

6.6 Wilcoxon-Test

6.7 Korrelation

6.8 Regression

6.9 Hauptkomponentenanalyse

7 Graphiken & Export von Ergebnissen nach Excel

7.1 Graphiken in R

7.2 Export von Ergebnissen nach Excel

R-Befehle: 3 Seiten

- **Seite 1:**
  - Alle notwendigen Befehle für die Auswertungen von “normalen“ Forschungsprojekten
- **Seite 2:**
  - Erstellen von Graphiken & Export von Ergebnissen nach Excel
- **Seite 3:**
  - PLSPM (Partial least path square modelling) – über Standardverfahren hinausgehend & nicht relevant in diesem Kurs

R-Befehle: Seite 1

Installieren & Laden der (Zusatz-)Pakete

Bearbeiten von Variablen & Datensätzen

Häufigkeiten

Lageparameter & Streuungsmaße

Prof. Dr.
Godbersen

R (mosaic) – Key Commands

Get going

```
install.packages("xyz")
require(xyz) ← starting mosaic, psych, psy, ggplot2, openxlsx, plspm (required for each session)
```

Recoding, computing, formatting variables & creating new datasets:

Recoding (new) variables:

```
dataset$new_variable[dataset$old_variable=="XXX"] <- "new_value"
        → Please note: categorial values require quotes ("), numerical values not
```

Calucalting new variables:

```
dataset$new_variable  <- dataset$variable1 + dataset$variable2
```

Changing the the variable formats:

```
dataset$new_variable  <- as.numeric(dataset$variable)
        → factor to numeric
(1): dataset$variable <- as.factor(dataset$variable)
(2): levels(dataset$variable) <- c("attribute1", "attribute1")
        → numeric to factor
```

Creating new datasets (is equal, is not equal etc.):

```
new_dataset <- dataset[dataset$variable == "value",]
new_dataset <- dataset[dataset$variable != "value",]
new_dataset <- dataset[dataset$variable > value,]
```

General command structure

```
command(y~x, z)
```

Frequencies

```
tally(~variable1, data = dataset)
        tally(~variable1, format = "percent", data = dataset)
tally(variable1~variable2, data = dataset)
        tally(variable1~variable2, format = "percent", data = dataset)
```

Median, mean, variance, standard deviation, maximum, minimum

```
median(~variable, data = dataset)   /   mean(~variable, data = dataset)
var(~variable, data = dataset)      /   sd(~variable, data = dataset)
max(~variable, data = dataset)      /   min(~variable, data = dataset)
favstats(~variable, data = dataset)
        → result: Min, Q1, median, Q3,  Max , mean, standard deviation, n, missing values)
```

Prof. Dr. Hendrik Godbersen: R (mosaic) – Key Commands 1

Prof. Dr.
Godbersen

Chi² test

```
xchisq.test(variable1~variable2, data = dataset)
```

t-test

```
t.test(variable~grouping_variable, data = dataset)
```

ANOVA

```
summary(aov(variable~grouping_variable, data = dataset))
→ alternative way:
modelxy <- aov(variable~grouping_variable, data = dataset)
summary(modelxy)
```

Shapiro-Wilk test

```
shapiro.test(dataset$variable)
```

Mann-Whitney & Wicoxon test

```
wilcox.test(variable~grouping_variable, data = dataset)
(→Mann-Whitney test)
wilcox.test(dataset$variable1, dataset$variable2, paired = T)
(→ Wilcoxon signed rank test (paired sample))
```

Correlation

```
cor.test(variable1~variable2, data = dataset)
```

Linear regression

```
summary(lm(dependent_variable~independent_variable, data = dataset))
```

Multiple regression

```
summary(lm(dependent_variable~ind_variable1 + ind_variable2, data = dataset))
```

Principal Component analysis (package: psych)

```
dataset_new <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)
colnames(dataset_new) <- c("Item_1", "Item_2")
KMO(dataset_new)
pcaX <- princomp(dataset_new, scores = TRUE, cor = TRUE)
summary(pcaX)                plot(pcaX)
principal(dataset_new, nfactors = x, rotate = "varimax")
```

Cronbach's Alpha (package: psy)

```
factorX <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)
cronbach(factorX)
```

Prof. Dr. Hendrik Godbersen: R (mosaic) – Key Commands 2

Inferenzstatistische Verfahren

Hauptkomponenten-analyse & Cronbachs Alpha

R-Befehle: Befehlsstrukur

Prof. Dr.
Godbersen

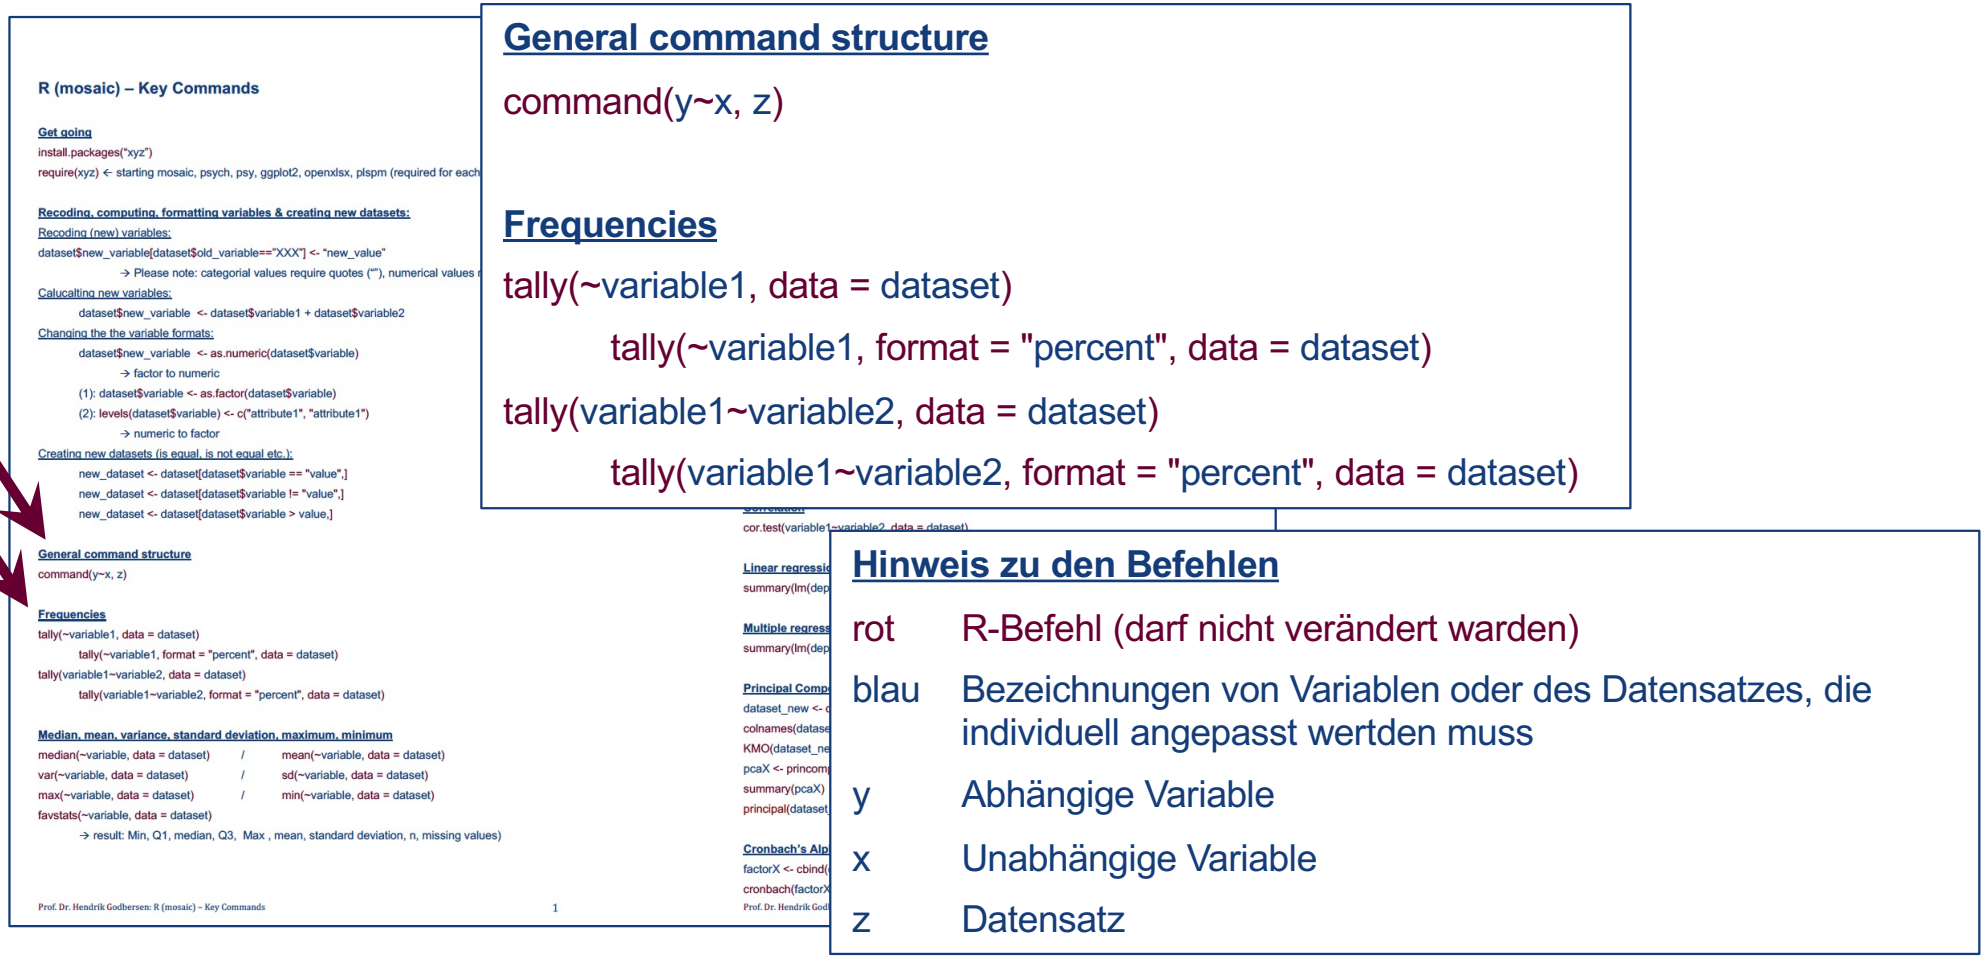

R (mosaic) – Key Commands

Get going
install.packages("xyz")
require(xyz) <- starting mosaic, psych, psy, ggplot2, openxlsx, plspm (required for each

Recoding, computing, formatting variables & creating new datasets:
Recoding (new) variables:
dataset$new_variable[dataset$old_variable=="XXX"] <- "new_value"
→ Please note: categorial values require quotes ("), numerical values
Calucalting new variables:
dataset$new_variable <- dataset$variable1 + dataset$variable2
Changing the the variable formats:
dataset$new_variable <- as.numeric(dataset$variable)
→ factor to numeric
(1): dataset$variable <- as.factor(dataset$variable)
(2): levels(dataset$variable) <- c("attribute1", "attribute1")
→ numeric to factor
Creating new datasets (is equal, is not equal etc.):
new_dataset <- dataset[dataset$variable == "value",]
new_dataset <- dataset[dataset$variable != "value",]
new_dataset <- dataset[dataset$variable > value,]

General command structure
command(y~x, z)

Frequencies
tally(~variable1, data = dataset)
tally(~variable1, format = "percent", data = dataset)
tally(variable1~variable2, data = dataset)
tally(variable1~variable2, format = "percent", data = dataset)

Median, mean, variance, standard deviation, maximum, minimum
median(~variable, data = dataset) / mean(~variable, data = dataset)
var(~variable, data = dataset) / sd(~variable, data = dataset)
max(~variable, data = dataset) / min(~variable, data = dataset)
favstats(~variable, data = dataset)
→ result: Min, Q1, median, Q3, Max , mean, standard deviation, n, missing values)

Prof. Dr. Hendrik Godbersen: R (mosaic) – Key Commands 1

cor.test(variable1~variable2, data = dataset)
Linear regressi
summary(lm(dep
Multiple regress
summary(lm(dep
Principal Comp
dataset_new <-
colnames(datase
KMO(dataset_ne
pcaX <- princom
summary(pcaX)
principal(dataset
Cronbach's Alp
factorX <- cbind(
cronbach(factorX
Prof. Dr. Hendrik God

General command structure

command(y~x, z)

Frequencies

tally(~variable1, data = dataset)

tally(~variable1, format = "percent", data = dataset)

tally(variable1~variable2, data = dataset)

tally(variable1~variable2, format = "percent", data = dataset)

Hinweis zu den Befehlen

rot	R-Befehl (darf nicht verändert warden)
blau	Bezeichnungen von Variablen oder des Datensatzes, die individuell angepasst wertden muss
y	Abhängige Variable
x	Unabhängige Variable
z	Datensatz

Inhalt

1 Einleitung

2 Installation & Grundstruktur von R Studio

2.1 Installation von R, R Studio & relevanten Paketen

2.2 Grundstruktur von R Studio

3 R-Befehle & Übungsdaten

3.1 R-Befehle

3.2 Übungsdaten

4 Datenmanagement

4.1 Datenvorbereitung & Laden von Daten

4.2 Daten bearbeiten in R

5 Deskriptive Statistik

5.1 Skalenniveaus

5.2 Häufigkeiten

5.3 Lageparameter & Streuungsmaße

6 Inferenzstatistische Verfahren

6.1 Überblick & Systematisierung der Verfahren

6.2 Chi-Quadrat-Test

6.3 t-Test

6.4 ANOVA

6.5 Shapiro-Wilk-Test

6.6 Wilcoxon-Test

6.7 Korrelation

6.8 Regression

6.9 Hauptkomponentenanalyse

7 Graphiken & Export von Ergebnissen nach Excel

7.1 Graphiken in R

7.2 Export von Ergebnissen nach Excel

Übungsdaten: Untersuchungsmodell

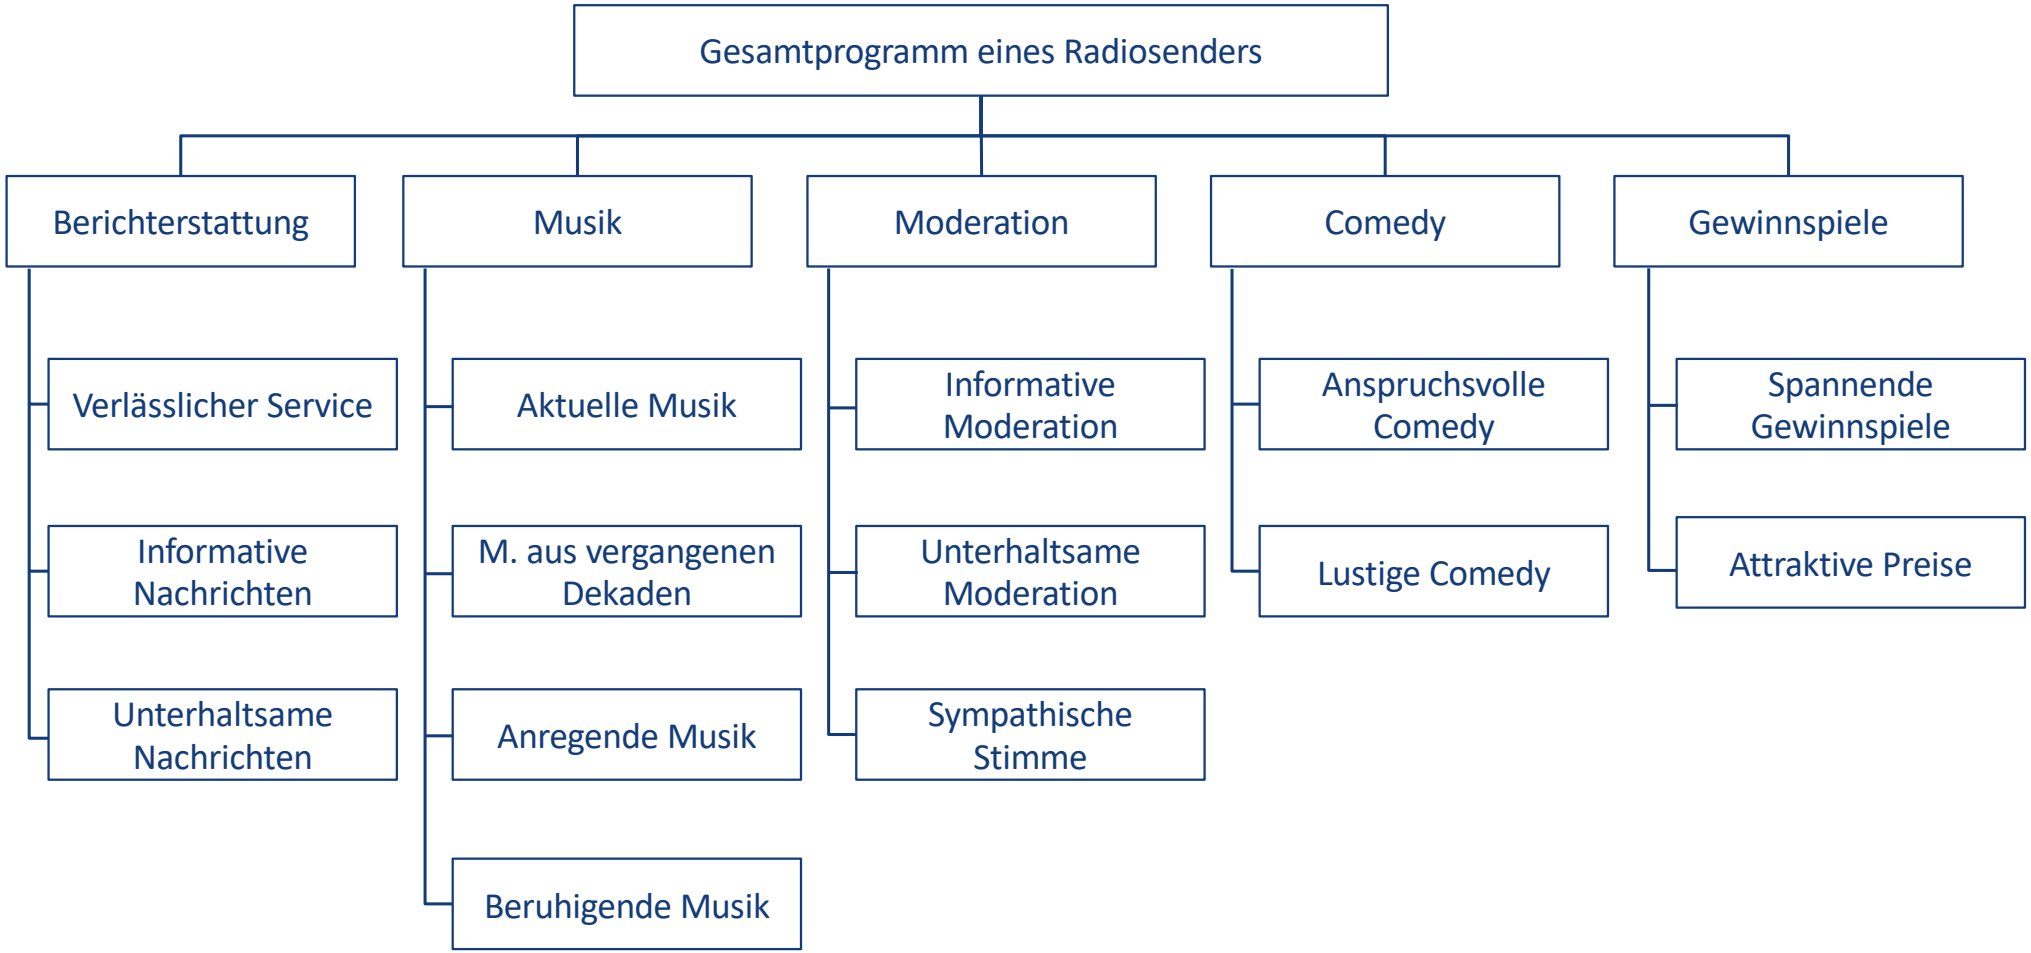

Übungsdaten: Fragebogen & Variablen

- Stammsender
  - Messung: in den letzten 2 Wochen am häufigster gehörter Sender
- SenderCluster
  - Messung: neu gebildete Variable mit drei Ausprägungen
  - Merkmalsausprägungen: SWR / Privat jung / Privat alt
- Programmeigenschaften
  - Messung: Continuous Rating Scale von 0 (nicht gut) bis 100 (sehr gut)
  - 14 Items
    - Verlaesslicher_Service
    - Informative_Nachrichten
    - Unterhaltsame_Nachrichten
    - Aktuelle_Musik
    - Alte_Musik
    - Anregende_Musik
    - Beruhigende_Musik
    - Informative_Moderation
    - Unterhaltsame_Moderation
    - Sympathische_Stimme
    - Anspruchsvolle_Comedy
    - Lustige_Comedy
    - Spannende_Gewinnspiele
    - Attraktive_Preise

Hinweis: Variablennamen in rot

- Programmelemente
  - Messung: Continuous Rating Scale von 0 (nicht gut) bis 100 (sehr gut)
  - 5 Items
    - Berichterstattung
    - Musik
    - Moderation
    - Comedy
    - Gewinnspiele
- Gesamtprogramm
  - Messung: Continuous Rating Scale von 0 (nicht gut) bis 100 (sehr gut)
- Geschlecht
  - Messung: Auswahlfrage
- Alter
  - Messung: offene Altersangabe
- Altersgruppen (alt vs. jung, 2 Gruppen)
- Aktuelle_ Musik_A (Affinität, 2 Gruppen)

Inhalt

1 Einleitung

2 Installation & Grundstruktur von R Studio

2.1 Installation von R, R Studio & relevanten Paketen

2.2 Grundstruktur von R Studio

3 R-Befehle & Übungsdaten

3.1 R-Befehle

3.2 Übungsdaten

4 Datenmanagement

4.1 Datenvorbereitung & Laden von Daten

4.2 Daten bearbeiten in R

5 Deskriptive Statistik

5.1 Skalenniveaus

5.2 Häufigkeiten

5.3 Lageparameter & Streuungsmaße

6 Inferenzstatistische Verfahren

6.1 Überblick & Systematisierung der Verfahren

6.2 Chi-Quadrat-Test

6.3 t-Test

6.4 ANOVA

6.5 Shapiro-Wilk-Test

6.6 Wilcoxon-Test

6.7 Korrelation

6.8 Regression

6.9 Hauptkomponentenanalyse

7 Graphiken & Export von Ergebnissen nach Excel

7.1 Graphiken in R

7.2 Export von Ergebnissen nach Excel

Datenvorbereitung & Laden von Daten: Erstellen des Datensatzes

- **1. Schritt:**
  - Datentabelle im Excel-Format erstellen (auch andere Formate sind möglich)
    - Aus **Online-Fragebogen** im Excel-Format herunterladen
    - Von **schriftlicher Fragebogen** in Excel eintragen
- **Datenstruktur:**
  - 1. Zeile = Variablenbezeichnungen
  - 1 Spalte = 1 Variable
  - 1 Zeile = 1 Befragter
- **Empfehlung:**
  - Nur vollständige Datensätze in die Auswertung nehmen
- **Voraussetzungen für die Auswertung mit R:**
  - **Variablenbezeichnungen:** keine Leerzeichen & keine Umlaute
    - Empfehlung: kurze & bedeutungsvolle Bezeichnungen
  - **Merkmalsausprägungen:**
    - Metrische Variablen (z.B. Alter) als numerischen Wert
    - Kategoriale Variablen (z.B. Geschlecht) als Text

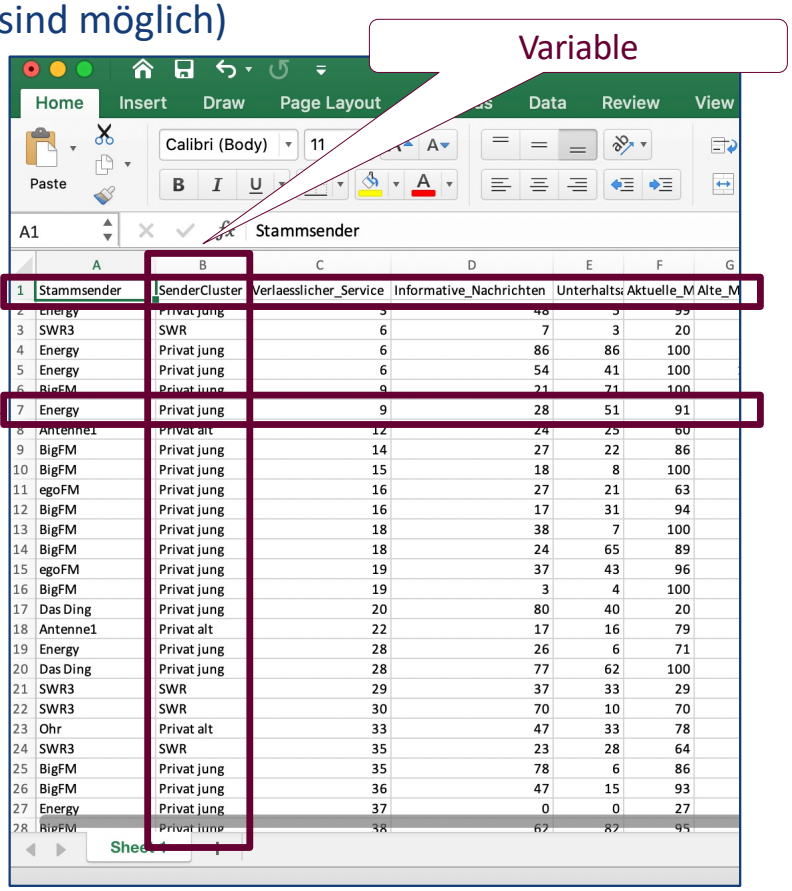

	A	B	C	D	E	F
1	Stammsender	SenderCluster	Verlaesslicher_Service	Informative_Nachrichten	Unterhalts	Aktuelle_M
2	Energy	Privat jung	3	48	3	99
3	SWR3	SWR	6	7	3	20
4	Energy	Privat jung	6	86	86	100
5	Energy	Privat jung	6	54	41	100
6	BigFM	Privat jung	9	21	71	100
7	Energy	Privat jung	9	28	51	91
8	Antenne1	Privat alt	12	24	25	60
9	BigFM	Privat jung	14	27	22	86
10	BigFM	Privat jung	15	18	8	100
11	egoFM	Privat jung	16	27	21	63
12	BigFM	Privat jung	16	17	31	94
13	BigFM	Privat jung	18	38	7	100
14	BigFM	Privat jung	18	24	65	89
15	egoFM	Privat jung	19	37	43	96
16	BigFM	Privat jung	19	3	4	100
17	Das Ding	Privat jung	20	80	40	20
18	Antenne1	Privat alt	22	17	16	79
19	Energy	Privat jung	28	26	6	71
20	Das Ding	Privat jung	28	77	62	100
21	SWR3	SWR	29	37	33	29
22	SWR3	SWR	30	70	10	70
23	Ohr	Privat alt	33	47	33	78
24	SWR3	SWR	35	23	28	64
25	BigFM	Privat jung	35	78	6	86
26	BigFM	Privat jung	36	47	15	93
27	Energy	Privat jung	37	0	0	27
28	BigFM	Privat jung	38	62	82	95

Datenvorbereitung & Laden von Daten: Daten in R laden

- **Vorbereitung (<u>wichtig</u>):**
  - Speichern Sie die Daten in einem Ordner auf Ihrem Computer, der extra für das Projekt angelegt ist
- **Daten aus Excel importieren (1):**
  - Unter „Environment“ Daten über „Import Dataset“ Excel-Daten auswählen
- **Daten im R-Format speichern (2):**
  - Unter Environment über Speichersymbol Daten im Projektordner speichern
- **Daten im R-Format laden (3):**
  - Unter „Environment“ Daten über Öffnungssymbol R-Daten auswählen
  - Unter „Environment“ auf den Datensatz klicken
  - In der Console generierten Befehle in das Script kopieren (4)
  - **Bei der nächsten Anwendung können die Daten über das Script gestartet werden (5)**

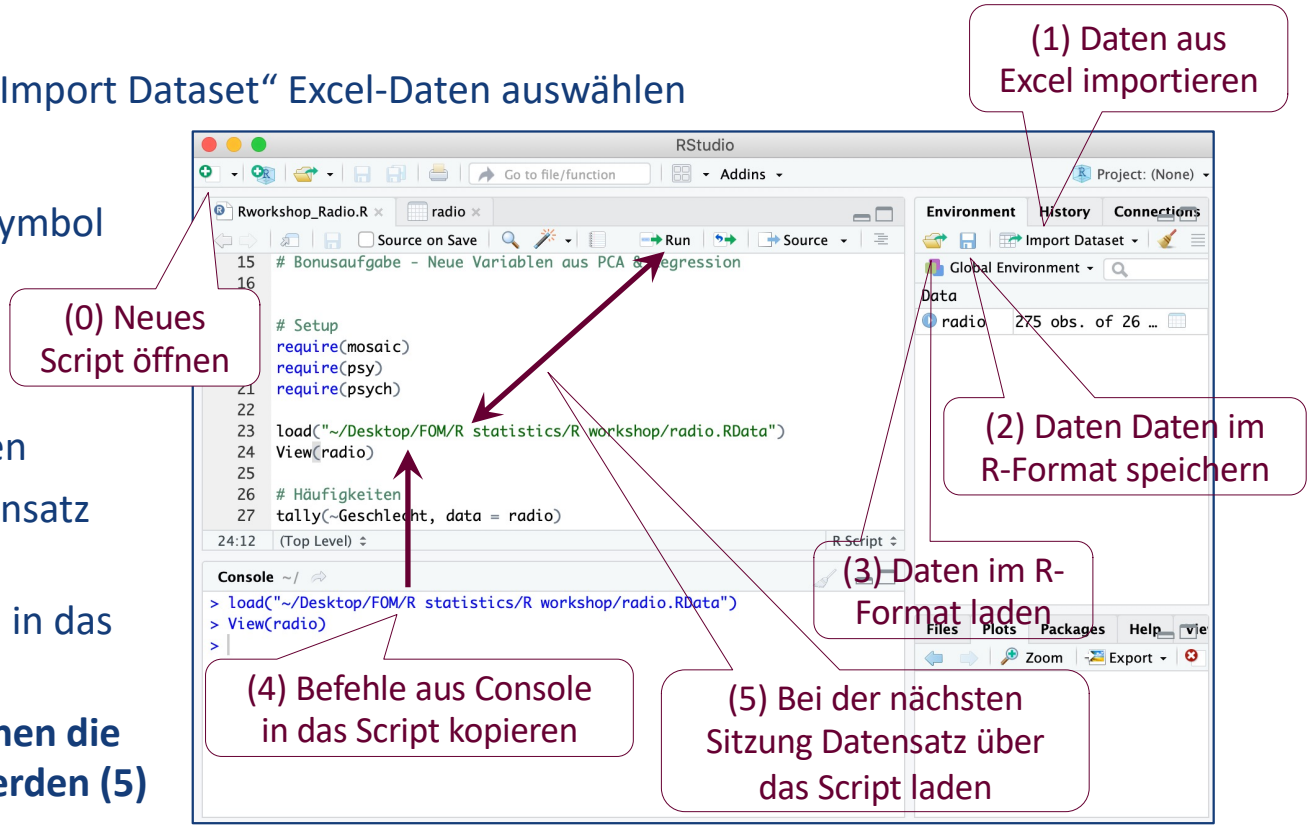

Inhalt

1 Einleitung

2 Installation & Grundstruktur von R Studio

2.1 Installation von R, R Studio & relevanten Paketen

2.2 Grundstruktur von R Studio

3 R-Befehle & Übungsdaten

3.1 R-Befehle

3.2 Übungsdaten

4 Datenmanagement

4.1 Datenvorbereitung & Laden von Daten

4.2 Daten bearbeiten in R

5 Deskriptive Statistik

5.1 Skalenniveaus

5.2 Häufigkeiten

5.3 Lageparameter & Streuungsmaße

6 Inferenzstatistische Verfahren

6.1 Überblick & Systematisierung der Verfahren

6.2 Chi-Quadrat-Test

6.3 t-Test

6.4 ANOVA

6.5 Shapiro-Wilk-Test

6.6 Wilcoxon-Test

6.7 Korrelation

6.8 Regression

6.9 Hauptkomponentenanalyse

7 Graphiken & Export von Ergebnissen nach Excel

7.1 Graphiken in R

7.2 Export von Ergebnissen nach Excel

Daten bearbeiten in R: Beispiele

- Recodieren von Variablen:
  - Inverse Skalen, z.B. 1 zu 6, 2 zu 5, 3 zu 4…
  - Zusammenfassen von Werten, z.B. Einwohner von Bayern und Baden-Württemberg (erhobene Variable) zu Süddeutschland (neu zu bildende Variable)
  - Ändern von metrischen zu kategorialen Werte (siehe Datenvorbereitung für R)
  - …

- Berechnen neuer Variablen:
  - Bildung eines neuen („übergeordneten“) Konstrukts aus mehreren Variablen, z.B. Berechnung einer Gesamtbewertung aus mehreren Einzelbewertungen über das arithmetische Mittel
  - Berechnung einer neuen Variable, die sich aus dem Verhältnis mehrerer Variablen bestimmt, z.B. Berechnung der Rentabilität aus den Variablen Gewinn und Umsatz
  - …

- Erstellen neuer Datensätze:
  - Ausschluss von Befragten mit bestimmten Merkmalsausprägungen, z.B. zu alte oder zu junge Befragte
  - Analyse nur eines Teils der Befragten, z.B. ausschließliche Analyse der Antworten von Frauen
  - …

Daten bearbeiten in R: Übungsaufgaben & R-Befehle

Aufgaben:

- Generieren Sie aus SenderCluster eine neue Variable (SenderCluster2): “Privat jung“ & „Privat alt“ zu „Privat“ und „SWR“ zu „SWR“.
- Berechnen Sie aus den Variablen „Comedy“ und „Gewinnspiele“ in einer neuen Variable (CoGe) den Mittelwert.
- Generieren Sie einen neuen Datensatz, der nur aus Frauen besteht.

Variablen

- Stammsender
- **SenderCluster**

- Verlaesslicher_Service
- Informative_Nachrichten
- Unterhaltsame_Nachrichten

- Berichterstattung
- Musik
- Moderation
- **Comedy**
- **Gewinnspiele**

- Gesamtprogramm

- **Geschlecht**
- Alter

- Altersgruppen
- Aktuelle_ Musik_A

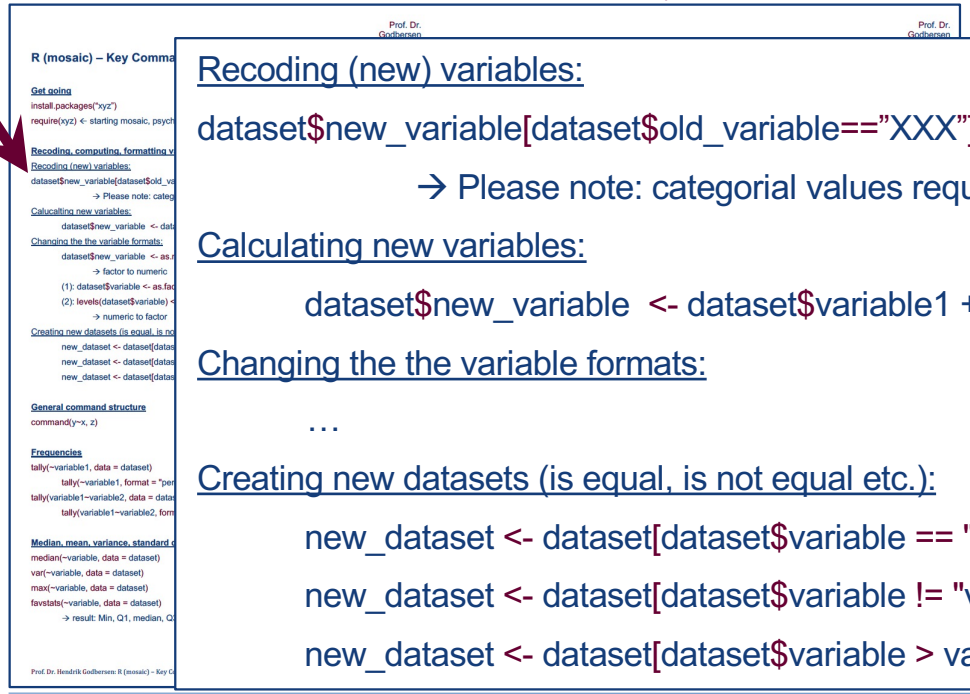

Recoding (new) variables:

dataset$new_variable[dataset$old_variable==”XXX”] <- “new_value”

→ Please note: categorial values require quotes (“”), numerical values not

Calculating new variables:

dataset$new_variable <- dataset$variable1 + dataset$variable2

Changing the the variable formats:

…

Creating new datasets (is equal, is not equal etc.):

new_dataset <- dataset[dataset$variable == "value",]

new_dataset <- dataset[dataset$variable != "value",]

new_dataset <- dataset[dataset$variable > value,]

Inhalt

1 Einleitung

2 Installation & Grundstruktur von R Studio

2.1 Installation von R, R Studio & relevanten Paketen

2.2 Grundstruktur von R Studio

3 R-Befehle & Übungsdaten

3.1 R-Befehle

3.2 Übungsdaten

4 Datenmanagement

4.1 Datenvorbereitung & Laden von Daten

4.2 Daten bearbeiten in R

5 Deskriptive Statistik

5.1 Skalenniveaus

5.2 Häufigkeiten

5.3 Lageparameter & Streuungsmaße

6 Inferenzstatistische Verfahren

6.1 Überblick & Systematisierung der Verfahren

6.2 Chi-Quadrat-Test

6.3 t-Test

6.4 ANOVA

6.5 Shapiro-Wilk-Test

6.6 Wilcoxon-Test

6.7 Korrelation

6.8 Regression

6.9 Hauptkomponentenanalyse

7 Graphiken & Export von Ergebnissen nach Excel

7.1 Graphiken in R

7.2 Export von Ergebnissen nach Excel

Inhalt

1 Einleitung

2 Installation & Grundstruktur von R Studio

2.1 Installation von R, R Studio & relevanten Paketen

2.2 Grundstruktur von R Studio

3 R-Befehle & Übungsdaten

3.1 R-Befehle

3.2 Übungsdaten

4 Datenmanagement

4.1 Datenvorbereitung & Laden von Daten

4.2 Daten bearbeiten in R

5 Deskriptive Statistik

5.1 Skalenniveaus

5.2 Häufigkeiten

5.3 Lageparameter & Streuungsmaße

6 Inferenzstatistische Verfahren

6.1 Überblick & Systematisierung der Verfahren

6.2 Chi-Quadrat-Test

6.3 t-Test

6.4 ANOVA

6.5 Shapiro-Wilk-Test

6.6 Wilcoxon-Test

6.7 Korrelation

6.8 Regression

6.9 Hauptkomponentenanalyse

7 Graphiken & Export von Ergebnissen nach Excel

7.1 Graphiken in R

7.2 Export von Ergebnissen nach Excel

Skalenniveaus

Skalenniveau		Math. Eigenschaften	Beschreibung der Messwertcharakteristika	Beispiel	Lageparameter
Kategorial	Nominal	=/≠	Die Messwerte sind identisch oder nicht identisch.	Geschlecht	• Modus
	Ordinal	=/≠ ; </>	Die Messwerte sind größer, kleiner oder identisch.	Olympische Ränge	• Modus • Median
Metrisch	Intervall	=/≠ ; </> ; −; +	Die Distanz zwischen den Messwerten kann angegeben werden.	Temperatur	• Modus • Median • Arithm. Mittel
	Verhältnis	=/≠ ; </> ; +/− ; */÷	Die Distanz zwischen den Messwerten und deren Verhältnis kann angegeben werden.	Körpergröße	

Inhalt

1 Einleitung

2 Installation & Grundstruktur von R Studio

2.1 Installation von R, R Studio & relevanten Paketen

2.2 Grundstruktur von R Studio

3 R-Befehle & Übungsdaten

3.1 R-Befehle

3.2 Übungsdaten

4 Datenmanagement

4.1 Datenvorbereitung & Laden von Daten

4.2 Daten bearbeiten in R

5 Deskriptive Statistik

5.1 Skalenniveaus

5.2 Häufigkeiten

5.3 Lageparameter & Streuungsmaße

6 Inferenzstatistische Verfahren

6.1 Überblick & Systematisierung der Verfahren

6.2 Chi-Quadrat-Test

6.3 t-Test

6.4 ANOVA

6.5 Shapiro-Wilk-Test

6.6 Wilcoxon-Test

6.7 Korrelation

6.8 Regression

6.9 Hauptkomponentenanalyse

7 Graphiken & Export von Ergebnissen nach Excel

7.1 Graphiken in R

7.2 Export von Ergebnissen nach Excel

Häufigkeiten: Steckbrief

- Absolute Häufigkeit:
  - gibt an wie häufig ein Wert auftritt

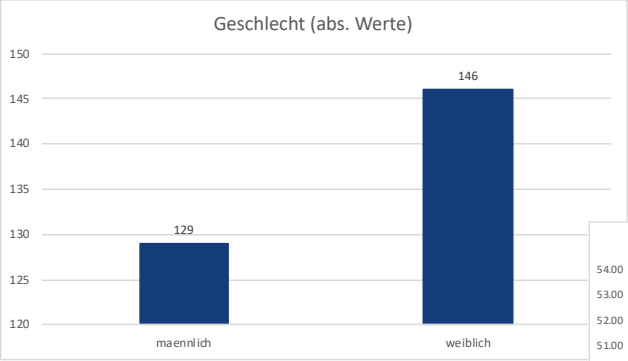

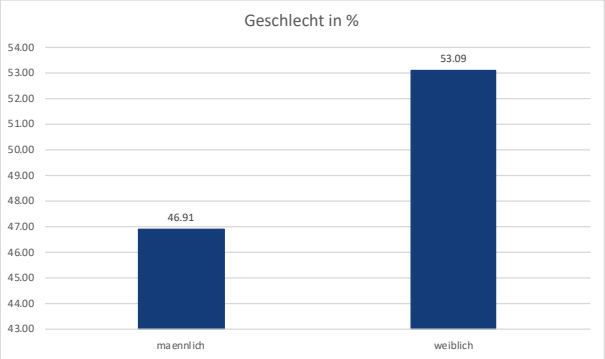

- Relative Häufigkeit:
  - gibt das Verhältnis eines untersuchten Merkmalsträgers zu einem Wert oder einer Klasse von Werten an

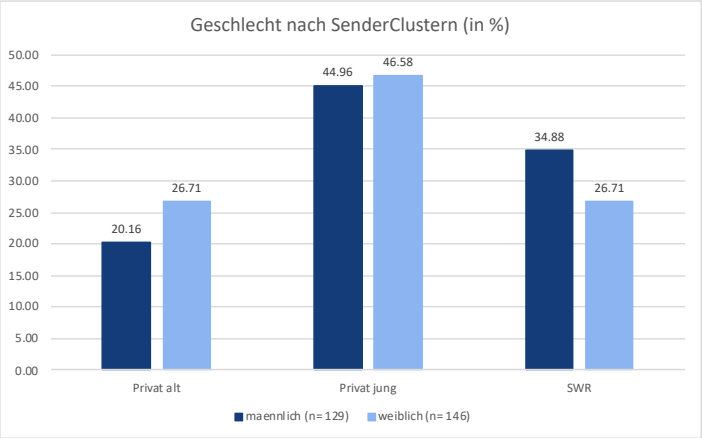

- Kreuztabelle:
  - Darstellung der gemeinsamen Verteilung zweier Variablen

Häufigkeiten: Übungsaufgaben & R-Befehle (1)

Aufgaben:

- Wie viele Männer und Frauen gibt es in der Stichprobe?
- Wie hoch ist der Anteil der Männer und Frauen in %?
- Wie hoch ist der Anteil der SenderCluster in %?

Frequencies

tally(~variable1, data = dataset)

tally(~variable1, format = "percent", data = dataset)

tally(variable1~variable2, data = dataset)

tally(variable1~variable2, format = "percent", data = dataset)

→ numeric to factor

Creating new datasets (is equal, is not equal etc.):

```
new_dataset <- dataset[dataset$variable == "value",]
new_dataset <- dataset[dataset$variable != "value",]
new_dataset <- dataset[dataset$variable > value,]
```

General command structure

```
command(y~x, z)
```

Frequencies

```
tally(~variable1, data = dataset)
    tally(~variable1, format = "percent", data = dataset)
tally(variable1~variable2, data = dataset)
    tally(variable1~variable2, format = "percent", data = dataset)
```

Median, mean, variance, standard deviation, maximum, minimum

```
median(~variable, data = dataset)   /   mean(~variable, data = dataset)
var(~variable, data = dataset)      /   sd(~variable, data = dataset)
max(~variable, data = dataset)      /   min(~variable, data = dataset)
favstats(~variable, data = dataset)
```

→ result: Min, Q1, median, Q3, Max , mean, standard deviation, n, missing values)

Prof. Dr. Hendrik Godbersen: R (mosaic) – Key Commands 1

```
wilcox.test(dataset$variable1, dataset$variable2, paired = T)
```

(→ Wilcoxon signed rank test (paired sample))

Correlation

```
cor.test(variable1~variable2, data = dataset)
```

Linear regression

```
summary(lm(dependent_variable~independent_variable, data = dataset))
```

Multiple regression

```
summary(lm(dependent_variable~ind_variable1 + ind_variable2, data = dataset))
```

Principal Component analysis (package: psych)

```
dataset_new <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)
colnames(dataset_new) <- c("Item_1", "Item_2")
KMO(dataset_new)
pcaX <- princomp(dataset_new, scores = TRUE, cor = TRUE)
summary(pcaX)                plot(pcaX)
principal(dataset_new, nfactors = x, rotate = "varimax")
```

Cronbach's Alpha (package: psy)

```
factorX <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)
cronbach(factorX)
```

Prof. Dr. Hendrik Godbersen: R (mosaic) – Key Commands 2

Variablen

- Stammsender
- **SenderCluster**

- Verlaesslicher_Service
- Informative_Nachrichten
- Unterhaltsame_Nachrichten
- Aktuelle_Musik
- Alte_Musik
- Anregende_Musik
- Beruhigende_Musik
- Informative_Moderation
- Unterhaltsame_Moderation
- Sympathische_Stimme
- Anspruchsvolle_Comedy
- Lustige_Comedy
- Spannende_Gewinnspiele
- Attraktive_Preise

- Berichterstattung
- Musik
- Moderation
- Comedy
- Gewinnspiele

- Gesamtprogramm

- **Geschlecht**
- Alter

- Altersgruppen
- Aktuelle_ Musik_A

Häufigkeiten: Umsetzung in R (1)

Häufigkeiten: Übungsaufgaben & R-Befehle (2)

Aufgaben:

- Wie verteilen sich Männer und Frauen auf die SenderCluster (%)?

Frequencies

tally(~variable1, data = dataset)

tally(~variable1, format = "percent", data = dataset)

tally(variable1~variable2, data = dataset)

tally(variable1~variable2, format = "percent", data = dataset)

→ numeric to factor

Creating new datasets (is equal, is not equal etc.):

```
new_dataset <- dataset[dataset$variable == "value",]
new_dataset <- dataset[dataset$variable != "value",]
new_dataset <- dataset[dataset$variable > value,]
```

General command structure

```
command(y~x, z)
```

Frequencies

```
tally(~variable1, data = dataset)
    tally(~variable1, format = "percent", data = dataset)
tally(variable1~variable2, data = dataset)
    tally(variable1~variable2, format = "percent", data = dataset)
```

Median, mean, variance, standard deviation, maximum, minimum

```
median(~variable, data = dataset)   /   mean(~variable, data = dataset)
var(~variable, data = dataset)      /   sd(~variable, data = dataset)
max(~variable, data = dataset)      /   min(~variable, data = dataset)
favstats(~variable, data = dataset)
```

→ result: Min, Q1, median, Q3, Max , mean, standard deviation, n, missing values)

Prof. Dr. Hendrik Godbersen: R (mosaic) – Key Commands 1

```
wilcox.test(dataset$variable1, dataset$variable2, paired = T)
```

(→ Wilcoxon signed rank test (paired sample))

Correlation

```
cor.test(variable1~variable2, data = dataset)
```

Linear regression

```
summary(lm(dependent_variable~independent_variable, data = dataset))
```

Multiple regression

```
summary(lm(dependent_variable~ind_variable1 + ind_variable2, data = dataset))
```

Principal Component analysis (package: psych)

```
dataset_new <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)
colnames(dataset_new) <- c("Item_1", "Item_2")
KMO(dataset_new)
pcaX <- princomp(dataset_new, scores = TRUE, cor = TRUE)
summary(pcaX)                plot(pcaX)
principal(dataset_new, nfactors = x, rotate = "varimax")
```

Cronbach's Alpha (package: psy)

```
factorX <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)
cronbach(factorX)
```

Prof. Dr. Hendrik Godbersen: R (mosaic) – Key Commands 2

Variablen

- Stammsender
- **SenderCluster**

- Verlaesslicher_Service
- Informative_Nachrichten
- Unterhaltsame_Nachrichten
- Aktuelle_Musik
- Alte_Musik
- Anregende_Musik
- Beruhigende_Musik
- Informative_Moderation
- Unterhaltsame_Moderation
- Sympathische_Stimme
- Anspruchsvolle_Comedy
- Lustige_Comedy
- Spannende_Gewinnspiele
- Attraktive_Preise

- Berichterstattung
- Musik
- Moderation
- Comedy
- Gewinnspiele

- Gesamtprogramm

- **Geschlecht**
- Alter

- Altersgruppen
- Aktuelle_ Musik_A

Häufigkeiten: Umsetzung in R (2)

Inhalt

1 Einleitung

2 Installation & Grundstruktur von R Studio

2.1 Installation von R, R Studio & relevanten Paketen

2.2 Grundstruktur von R Studio

3 R-Befehle & Übungsdaten

3.1 R-Befehle

3.2 Übungsdaten

4 Datenmanagement

4.1 Datenvorbereitung & Laden von Daten

4.2 Daten bearbeiten in R

5 Deskriptive Statistik

5.1 Skalenniveaus

5.2 Häufigkeiten

5.3 Lageparameter & Streuungsmaße

6 Inferenzstatistische Verfahren

6.1 Überblick & Systematisierung der Verfahren

6.2 Chi-Quadrat-Test

6.3 t-Test

6.4 ANOVA

6.5 Shapiro-Wilk-Test

6.6 Wilcoxon-Test

6.7 Korrelation

6.8 Regression

6.9 Hauptkomponentenanalyse

7 Graphiken & Export von Ergebnissen nach Excel

7.1 Graphiken in R

7.2 Export von Ergebnissen nach Excel

Lageparameter & Streuungsmaße: Steckbrief

- **Lageparameter**:
  - Arithmetisches Mittel:
    - Division der Summe aller Werte durch die Anzahl der Werte; metrisches Skalenniveau notwendig
  - Median:
    - Wert, der die Grenze zwischen oberer und unterer Hälfte markiert; mindestens ordinales Skalenniveau
  - Modalwert:
    - Häufigste Wert einer Häufigkeitsverteilung; mindestens nominales Skalenniveau
- **Streuungsparameter**
  - Varianz
    - Durchschnittliche quadrierte Abweichung der gemessenen Werte vom arithmetischen Mittel (beachte: empirische Varianz → /n; Stichprobenvarianz → /n-1)

$$\sigma^2 = \frac{\sum_{i=1}^{n}(x_i - \bar{\bar{x}})^2}{n}$$

  - Standardabweichung
    - Durchschnittliche Abweichung der gemessenen Werte vom arithmetischen Mittel

$$\sigma = \sqrt{\sigma^2}$$

Lageparameter & Streuungsmaße: Steckbrief

- **Streuungsparameter**
  - Varianz

$$\sigma^2 = \frac{\sum_{i=1}^{n}(x_i - \bar{\bar{x}})^2}{n}$$

  - Standardabweichung

$$\sigma = \sqrt{\sigma^2}$$

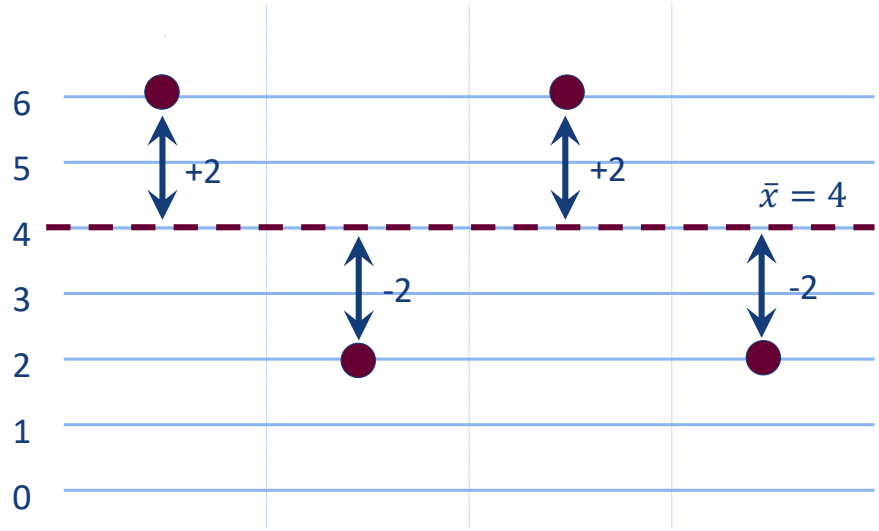

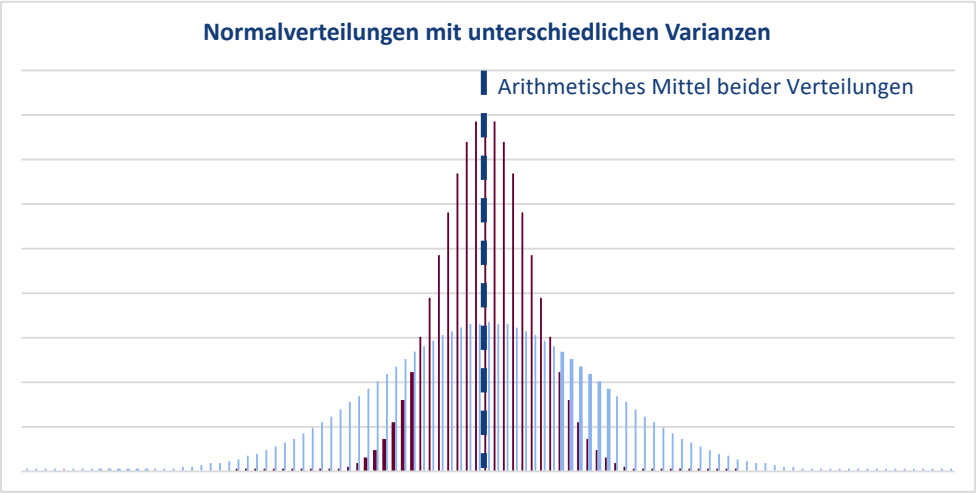

$\sum_{i=1}^{n}(x_i - \bar{\bar{x}})$ — (+2) + (-2) + (+2) + (-2) = 0

$\sum_{i=1}^{n}(x_i - \bar{\bar{x}})^2$ — $(+2)^2 + (-2)^2 + (+2)^2 + (-2)^2 =$ 4 + 4 + 4 + 4 = 16

$\sigma^2 = \frac{\sum_{i=1}^{n}(x_i - \bar{\bar{x}})^2}{n}$ — 16 / 4 = 4

$\sigma = \sqrt{\sigma^2}$ — $\sqrt{4} = 2$

Lageparameter & Streuungsmaße: Übungsaufgaben & R-Befehle (1)

Aufgaben:

- Was ist das durchschnittliche Alter der Befragten (arith. Mittel)?
- Welchen Wert hat der Median bei der Variable Alter?
- Wie stark streuen die gemessenen Werte der Variable Alter um das arithmetische Mittel (Varianz & Standardabweichung)?

Median, mean, variance, standard deviation, maximum, minimum

median(~variable, data = dataset) / mean(~variable, data = dataset)

var(~variable, data = dataset) / sd(~variable, data = dataset)

max(~variable, data = dataset) / min(~variable, data = dataset)

favstats(~variable, data = dataset)

```
new_dataset <- dataset[dataset$variable > value,]

General command structure
command(y~x, z)

Frequencies
tally(~variable1, data = dataset)
tally(~variable1, format = "percent", data = dataset)
tally(variable1~variable2, data = dataset)
tally(variable1~variable2, format = "percent", data = dataset)

Median, mean, variance, standard deviation, maximum, minimum
median(~variable, data = dataset)   /   mean(~variable, data = dataset)
var(~variable, data = dataset)      /   sd(~variable, data = dataset)
max(~variable, data = dataset)      /   min(~variable, data = dataset)
favstats(~variable, data = dataset)
→ result: Min, Q1, median, Q3, Max , mean, standard deviation, n, missing values)
```



```
Correlation
cor.test(variable1~variable2, data = dataset)

Linear regression
summary(lm(dependent_variable~independent_variable, data = dataset))

Multiple regression
summary(lm(dependent_variable~ind_variable1 + ind_variable2, data = dataset))

Principal Component analysis (package: psych)
dataset_new <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)
colnames(dataset_new) <- c("Item_1", "Item_2")
KMO(dataset_new)
pcaX <- princomp(dataset_new, scores = TRUE, cor = TRUE)
summary(pcaX)                plot(pcaX)
principal(dataset_new, nfactors = x, rotate = "varimax")

Cronbach's Alpha (package: psy)
factorX <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)
cronbach(factorX)
```


Variablen

- Stammsender
- SenderCluster

- Verlaesslicher_Service
- Informative_Nachrichten
- Unterhaltsame_Nachrichten
- Aktuelle_Musik
- Alte_Musik
- Anregende_Musik
- Beruhigende_Musik
- Informative_Moderation
- Unterhaltsame_Moderation
- Sympathische_Stimme
- Anspruchsvolle_Comedy
- Lustige_Comedy
- Spannende_Gewinnspiele
- Attraktive_Preise

- Berichterstattung
- Musik
- Moderation
- Comedy
- Gewinnspiele

- Gesamtprogramm

- Geschlecht
- **Alter**

- Altersgruppen
- Aktuelle_ Musik_A

Lageparameter & Streuungsmaße: Umsetzung in R (1)

Lageparameter & Streuungsmaße: Übungsaufgaben & R-Befehle (2)

Aufgaben:

- Wie hoch ist die durchschnittliche Bewertung des Gesamtprogramms (arith. Mittel)?
- Welchen Wert hat der Median bei der Variable Gesamtprogramm?
- Wie stark streuen die gemessenen Werte der Variable Gesamtprogramm um das arithmetische Mittel (Varianz & Standardabweichung)?

Median, mean, variance, standard deviation, maximum, minimum

median(~variable, data = dataset) / mean(~variable, data = dataset)

var(~variable, data = dataset) / sd(~variable, data = dataset)

max(~variable, data = dataset) / min(~variable, data = dataset)

favstats(~variable, data = dataset)


```
new_dataset <- dataset[dataset$variable > value,]
```

General command structure

```
command(y~x, z)
```

Frequencies

```
tally(~variable1, data = dataset)
        tally(~variable1, format = "percent", data = dataset)
tally(variable1~variable2, data = dataset)
        tally(variable1~variable2, format = "percent", data = dataset)
```

Median, mean, variance, standard deviation, maximum, minimum

```
median(~variable, data = dataset)   /   mean(~variable, data = dataset)
var(~variable, data = dataset)      /   sd(~variable, data = dataset)
max(~variable, data = dataset)      /   min(~variable, data = dataset)
favstats(~variable, data = dataset)
        → result: Min, Q1, median, Q3,  Max , mean, standard deviation, n, missing values)
```


Correlation

```
cor.test(variable1~variable2, data = dataset)
```

Linear regression

```
summary(lm(dependent_variable~independent_variable, data = dataset))
```

Multiple regression

```
summary(lm(dependent_variable~ind_variable1 + ind_variable2, data = dataset))
```

Principal Component analysis (package: psych)

```
dataset_new <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)
colnames(dataset_new) <- c("Item_1", "Item_2")
KMO(dataset_new)
pcaX <- princomp(dataset_new, scores = TRUE, cor = TRUE)
summary(pcaX)                    plot(pcaX)
principal(dataset_new, nfactors = x, rotate = "varimax")
```

Cronbach's Alpha (package: psy)

```
factorX <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)
cronbach(factorX)
```


Variablen

- Stammsender
- SenderCluster

- Verlaesslicher_Service
- Informative_Nachrichten
- Unterhaltsame_Nachrichten
- Aktuelle_Musik
- Alte_Musik
- Anregende_Musik
- Beruhigende_Musik
- Informative_Moderation
- Unterhaltsame_Moderation
- Sympathische_Stimme
- Anspruchsvolle_Comedy
- Lustige_Comedy
- Spannende_Gewinnspiele
- Attraktive_Preise

- Berichterstattung
- Musik
- Moderation
- Comedy
- Gewinnspiele

- **Gesamtprogramm**

- Geschlecht
- Alter

- Altersgruppen
- Aktuelle_ Musik_A

Lageparameter & Streuungsmaße: Umsetzung in R (2)

Lageparameter & Streuungsmaße: Übungsaufgaben & R-Befehle (3)

Aufgaben:

- Bestimmen Sie für die Variable Alter das arithmetische Mittel, den Median, die Standardabweichung etc. mit nur einem R-Befehl.
- Bestimmen Sie für die Variable Gesamtprogramm das arithmetische Mittel, den Median, die Standardabweichung etc. mit nur einem R-Befehl.

Median, mean, variance, standard deviation, maximum, minimum

median(~variable, data = dataset) / mean(~variable, data = dataset)

var(~variable, data = dataset) / sd(~variable, data = dataset)

max(~variable, data = dataset) / min(~variable, data = dataset)

favstats(~variable, data = dataset)

```
new_dataset <- dataset[dataset$variable > value,]
```

General command structure

```
command(y~x, z)
```

Frequencies

```
tally(~variable1, data = dataset)
    tally(~variable1, format = "percent", data = dataset)
tally(variable1~variable2, data = dataset)
    tally(variable1~variable2, format = "percent", data = dataset)
```

Median, mean, variance, standard deviation, maximum, minimum

```
median(~variable, data = dataset)   /   mean(~variable, data = dataset)
var(~variable, data = dataset)      /   sd(~variable, data = dataset)
max(~variable, data = dataset)      /   min(~variable, data = dataset)
favstats(~variable, data = dataset)
    → result: Min, Q1, median, Q3,  Max , mean, standard deviation, n, missing values)
```


Correlation

```
cor.test(variable1~variable2, data = dataset)
```

Linear regression

```
summary(lm(dependent_variable~independent_variable, data = dataset))
```

Multiple regression

```
summary(lm(dependent_variable~ind_variable1 + ind_variable2, data = dataset))
```

Principal Component analysis (package: psych)

```
dataset_new <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)
colnames(dataset_new) <- c("Item_1", "Item_2")
KMO(dataset_new)
pcaX <- princomp(dataset_new, scores = TRUE, cor = TRUE)
summary(pcaX)                plot(pcaX)
principal(dataset_new, nfactors = x, rotate = "varimax")
```

Cronbach's Alpha (package: psy)

```
factorX <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)
cronbach(factorX)
```


Variablen

- Stammsender
- SenderCluster

- Verlaesslicher_Service
- Informative_Nachrichten
- Unterhaltsame_Nachrichten
- Aktuelle_Musik
- Alte_Musik
- Anregende_Musik
- Beruhigende_Musik
- Informative_Moderation
- Unterhaltsame_Moderation
- Sympathische_Stimme
- Anspruchsvolle_Comedy
- Lustige_Comedy
- Spannende_Gewinnspiele
- Attraktive_Preise

- Berichterstattung
- Musik
- Moderation
- Comedy
- Gewinnspiele

- **Gesamtprogramm**

- Geschlecht
- **Alter**

- Altersgruppen
- Aktuelle_ Musik_A

Lageparameter & Streuungsmaße: Umsetzung in R (3)

Lageparameter & Streuungsmaße: Übungsaufgaben & R-Befehle (4)

Aufgaben:

- Stellen Sie das durchschnittliche Alter von Männern und Frauen gegenüber (arith. Mittelwerte).
- Stellen Sie die durchschnittliche Bewertung des Gesamtprogramms von Männern und Frauen gegenüber (arith. Mittelwerte).

Median, mean, variance, standard deviation, maximum, minimum

median(~variable, data = dataset) / mean(~variable, data = dataset)

var(~variable, data = dataset) / sd(~variable, data = dataset)

max(~variable, data = dataset) / min(~variable, data = dataset)

favstats(~variable, data = dataset)

```
new_dataset <- dataset[dataset$variable > value,]
```

General command structure

```
command(y~x, z)
```

Frequencies

```
tally(~variable1, data = dataset)
    tally(~variable1, format = "percent", data = dataset)
tally(variable1~variable2, data = dataset)
    tally(variable1~variable2, format = "percent", data = dataset)
```

Median, mean, variance, standard deviation, maximum, minimum

```
median(~variable, data = dataset)   /   mean(~variable, data = dataset)
var(~variable, data = dataset)      /   sd(~variable, data = dataset)
max(~variable, data = dataset)      /   min(~variable, data = dataset)
favstats(~variable, data = dataset)
    → result: Min, Q1, median, Q3,  Max , mean, standard deviation, n, missing values)
```


Correlation

```
cor.test(variable1~variable2, data = dataset)
```

Linear regression

```
summary(lm(dependent_variable~independent_variable, data = dataset))
```

Multiple regression

```
summary(lm(dependent_variable~ind_variable1 + ind_variable2, data = dataset))
```

Principal Component analysis (package: psych)

```
dataset_new <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)
colnames(dataset_new) <- c("Item_1", "Item_2")
KMO(dataset_new)
pcaX <- princomp(dataset_new, scores = TRUE, cor = TRUE)
summary(pcaX)                    plot(pcaX)
principal(dataset_new, nfactors = x, rotate = "varimax")
```

Cronbach's Alpha (package: psy)

```
factorX <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)
cronbach(factorX)
```


Variablen

- Stammsender
- SenderCluster

- Verlaesslicher_Service
- Informative_Nachrichten
- Unterhaltsame_Nachrichten
- Aktuelle_Musik
- Alte_Musik
- Anregende_Musik
- Beruhigende_Musik
- Informative_Moderation
- Unterhaltsame_Moderation
- Sympathische_Stimme
- Anspruchsvolle_Comedy
- Lustige_Comedy
- Spannende_Gewinnspiele
- Attraktive_Preise

- Berichterstattung
- Musik
- Moderation
- Comedy
- Gewinnspiele

- **Gesamtprogramm**

- **Geschlecht**
- **Alter**

- Altersgruppen
- Aktuelle_ Musik_A

Lageparameter & Streuungsmaße: Umsetzung in R (4)

Inhalt

1 Einleitung

2 Installation & Grundstruktur von R Studio

2.1 Installation von R, R Studio & relevanten Paketen

2.2 Grundstruktur von R Studio

3 R-Befehle & Übungsdaten

3.1 R-Befehle

3.2 Übungsdaten

4 Datenmanagement

4.1 Datenvorbereitung & Laden von Daten

4.2 Daten bearbeiten in R

5 Deskriptive Statistik

5.1 Skalenniveaus

5.2 Häufigkeiten

5.3 Lageparameter & Streuungsmaße

6 Inferenzstatistische Verfahren

6.1 Überblick & Systematisierung der Verfahren

6.2 Chi-Quadrat-Test

6.3 t-Test

6.4 ANOVA

6.5 Shapiro-Wilk-Test

6.6 Wilcoxon-Test

6.7 Korrelation

6.8 Regression

6.9 Hauptkomponentenanalyse

7 Graphiken & Export von Ergebnissen nach Excel

7.1 Graphiken in R

7.2 Export von Ergebnissen nach Excel

Überblick & Systematisierung der Verfahren

Struktur	Unabhängige Variable
Abhän Varial	

Skalenniveau		Math. Eigenschaften	Beschreibung der Messwertcharakteristika	Beispiel	Lageparameter
Kategorial	Nominal	=/≠	Die Messwerte sind identisch oder nicht identisch.	Geschlecht	• Modus
	Ordinal	=/≠ ; </>	Die Messwerte sind größer, kleiner oder identisch.	Olympische Ränge	• Modus • Median
Metrisch	Intervall	=/≠ ; </> ; −; +	Die Distanz zwischen den Messwerten kann angegeben werden.	Temperatur	• Modus • Median • Arithm. Mittel
	Verhältnis	=/≠ ; </> ; +/− ; */÷	Die Distanz zwischen den Messwerten und deren Verhältnis kann angegeben werden.	Körpergröße	

*** „Ergä
• Sk
(p
• M
(p

Strukturentdeckende Verfahren	• Hauptkomponentenanalyse (Faktoranalyse) • Clusteranalyse

Überblick & Systematisierung der Verfahren

Strukturprüfende Verfahren		Unabhängige Variable	
		nicht-metrisch	metrisch
Abhängige Variable	nicht-metrisch	Chi^2-Test	Diskriminanzanalyse
	metrisch	t-Test*** (bei 2 Gruppen) & Varianzanalyse (bei ≥ 3 Gruppen)	Regressionsanalyse (Dependenz) & Korrelationsanalyse (Interdependenz)

*** „Ergänzende“ Tests:

- Shapiro-Wilk-Test
  (prüft Stichproben auf Normalverteilung, die für den t-Test notwendig ist)
- Mann-Whitney-Test/Wilcoxon-Test
  (prüft mind. ordinal skalierte Daten auf Unterschiede ohne Berücksichtigung der Verteilungsform)

Strukturentdeckende Verfahren	• Hauptkomponentenanalyse (Faktoranalyse) • Clusteranalyse

Inhalt

1 Einleitung
2 Installation & Grundstruktur von R Studio
2.1 Installation von R, R Studio & relevanten Paketen
2.2 Grundstruktur von R Studio
3 R-Befehle & Übungsdaten
3.1 R-Befehle
3.2 Übungsdaten
4 Datenmanagement
4.1 Datenvorbereitung & Laden von Daten
4.2 Daten bearbeiten in R
5 Deskriptive Statistik
5.1 Skalenniveaus
5.2 Häufigkeiten
5.3 Lageparameter & Streuungsmaße
6 Inferenzstatistische Verfahren
6.1 Überblick & Systematisierung der Verfahren
6.2 Chi-Quadrat-Test
6.3 t-Test
6.4 ANOVA
6.5 Shapiro-Wilk-Test
6.6 Wilcoxon-Test
6.7 Korrelation
6.8 Regression
6.9 Hauptkomponentenanalyse
7 Graphiken & Export von Ergebnissen nach Excel
7.1 Graphiken in R
7.2 Export von Ergebnissen nach Excel

Chi-Quadrat-Test: Steckbrief

- **Anwendung**:
  - Testen auf (Un-)Abhängigkeit bei nominalen Daten (Weichen die gemessenen Werte nicht-zufällig von den erwarteten Werten ab?)
- **Fragestellung**:
  - Gibt es einen „nicht-zufälligen“ statistischen Zusammenhang zwischen zwei nominalskalierten Merkmalen? Sind zwei kategoriale Variablen unabhängig?
- **Vorgehen bei der Analyse**:
  1) Ist der p-value <0.05 (<0.01, <0.001)? → Signifikanz?
  2) Wie unterscheiden sich die Häufigkeiten?
- **„Statistischen“ Analyseschritte („im Hintergrund“)**:
  1) Berechnung der erwarteten Häufigkeiten (e), wenn kein Unterschied zwischen den Variablen bestehen würde (Spaltensumme * Zeilensumme / Merkmalsträger)
  2) Bestimmung, ob die gemessenen Werte (h) signifikant von den erwarteten Werten abweichen?

	männlich	weiblich	Summe
blau	h = 35 e = 25	h = 15 e = 25	50
rot	h = 15 e = 25	h = 35 e = 25	50
Summe	50	50	100

Chi-Quadrat-Test: Steckbrief

- **„Statistischen“ Analyseschritte („im Hintergrund“)**:
  1) Berechnung der erwarteten Häufigkeiten (e), wenn kein Unterschied zwischen den Variablen bestehen würde (Spaltensumme * Zeilensumme / Merkmalsträger)
  2) Bestimmung, ob die gemessenen Werte (h) signifikant von den erwarteten Werten abweichen?

V1	männlich	weiblich	Summe
blau	h = 15 e = 25	h = 35 e = 25	50
rot	h = 35 e = 25	h = 15 e = 25	50
Summe	50	50	100

p-value = 0.0001447

V2	männlich	weiblich	Summe
blau	h = 24 e = 25	h = 26 e = 25	50
rot	h = 26 e = 25	h = 24 e = 25	50
Summe	50	50	100

p-value = 0.8415

Chi-Quadrat-Test: Übungsaufgaben & R-Befehle

Aufgaben:

- Besteht ein signifikanter Unterschied zwischen Männern und Frauen bei der Präferenz für die SenderCluster?
- Unterscheidet sich das junge und alte Alterssegment bei der Affinität zu aktueller Musik? Und wenn ja, wie fällt dieser Unterschied aus?

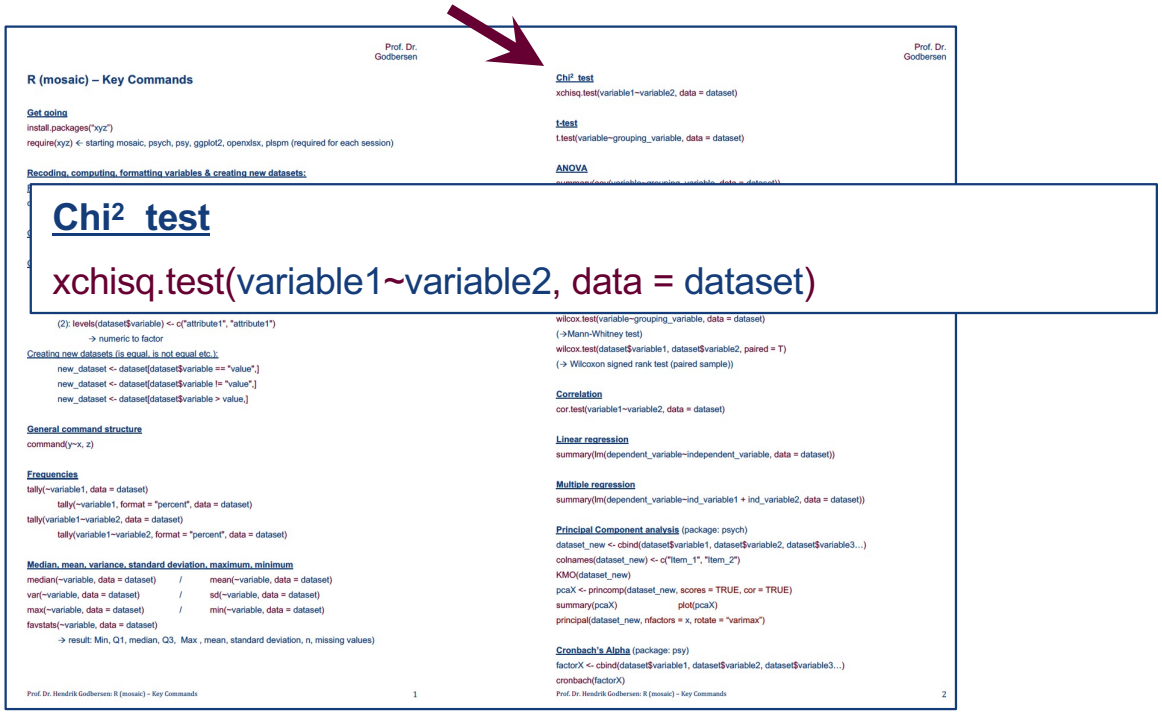

Prof. Dr. Godbersen

R (mosaic) – Key Commands

Get going
install.packages("xyz")
require(xyz) <- starting mosaic, psych, psy, ggplot2, openxlsx, plspm (required for each session)

Recoding, computing, formatting variables & creating new datasets:

(2): levels(dataset$variable) <- c("attribute1", "attribute1")
→ numeric to factor

Creating new datasets (is equal, is not equal etc.):
new_dataset <- dataset[dataset$variable == "value",]
new_dataset <- dataset[dataset$variable != "value",]
new_dataset <- dataset[dataset$variable > value,]

General command structure
command(y~x, z)

Frequencies
tally(~variable1, data = dataset)
tally(~variable1, format = "percent", data = dataset)
tally(variable1~variable2, data = dataset)
tally(variable1~variable2, format = "percent", data = dataset)

Median, mean, variance, standard deviation, maximum, minimum
median(~variable, data = dataset) / mean(~variable, data = dataset)
var(~variable, data = dataset) / sd(~variable, data = dataset)
max(~variable, data = dataset) / min(~variable, data = dataset)
favstats(~variable, data = dataset)
→ result: Min, Q1, median, Q3, Max , mean, standard deviation, n, missing values)

Prof. Dr. Hendrik Godbersen: R (mosaic) – Key Commands 1

Prof. Dr. Godbersen

Chi² test
xchisq.test(variable1~variable2, data = dataset)

t-test
t.test(variable~grouping_variable, data = dataset)

ANOVA

wilcox.test(variable~grouping_variable, data = dataset)
(→Mann-Whitney test)
wilcox.test(dataset$variable1, dataset$variable2, paired = T)
(→ Wilcoxon signed rank test (paired sample))

Correlation
cor.test(variable1~variable2, data = dataset)

Linear regression
summary(lm(dependent_variable~independent_variable, data = dataset))

Multiple regression
summary(lm(dependent_variable~ind_variable1 + ind_variable2, data = dataset))

Principal Component analysis (package: psych)
dataset_new <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)
colnames(dataset_new) <- c("Item_1", "Item_2")
KMO(dataset_new)
pcaX <- princomp(dataset_new, scores = TRUE, cor = TRUE)
summary(pcaX) plot(pcaX)
principal(dataset_new, nfactors = x, rotate = "varimax")

Cronbach's Alpha (package: psy)
factorX <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)
cronbach(factorX)

Prof. Dr. Hendrik Godbersen: R (mosaic) – Key Commands 2

Chi² test

xchisq.test(variable1~variable2, data = dataset)

Variablen

- Stammsender
- **SenderCluster**

- Verlaesslicher_Service
- Informative_Nachrichten
- Unterhaltsame_Nachrichten
- Aktuelle_Musik
- Alte_Musik
- Anregende_Musik
- Beruhigende_Musik
- Informative_Moderation
- Unterhaltsame_Moderation
- Sympathische_Stimme
- Anspruchsvolle_Comedy
- Lustige_Comedy
- Spannende_Gewinnspiele
- Attraktive_Preise

- Berichterstattung
- Musik
- Moderation
- Comedy
- Gewinnspiele

- Gesamtprogramm

- **Geschlecht**
- Alter

- **Altersgruppen**
- **Aktuelle_ Musik_A**

Chi-Quadrat-Test: Umsetzung in R

Inhalt

1 Einleitung
2 Installation & Grundstruktur von R Studio
2.1 Installation von R, R Studio & relevanten Paketen
2.2 Grundstruktur von R Studio
3 R-Befehle & Übungsdaten
3.1 R-Befehle
3.2 Übungsdaten
4 Datenmanagement
4.1 Datenvorbereitung & Laden von Daten
4.2 Daten bearbeiten in R
5 Deskriptive Statistik
5.1 Skalenniveaus
5.2 Häufigkeiten
5.3 Lageparameter & Streuungsmaße
6 Inferenzstatistische Verfahren
6.1 Überblick & Systematisierung der Verfahren
6.2 Chi-Quadrat-Test
6.3 t-Test
6.4 ANOVA
6.5 Shapiro-Wilk-Test
6.6 Wilcoxon-Test
6.7 Korrelation
6.8 Regression
6.9 Hauptkomponentenanalyse
7 Graphiken & Export von Ergebnissen nach Excel
7.1 Graphiken in R
7.2 Export von Ergebnissen nach Excel

t-Test: Steckbrief

- **Anwendung**:
  - Der t-Test ist ein parametrisches Verfahren. Beim Zweistichproben-t-Test wird überprüft, ob sich eine metrische Variable zwischen zwei Stichproben signifikant (nicht zufällig) unterscheidet.
- **Fragestellung**:
  - Gibt es einen „nicht-zufälligen“ statistischen Unterschied zwischen zwei Stichproben in Bezug auf ein metrisches Merkmal?
  - Gibt es einen „nicht-zufälligen“ Einfluss einer nominalen Variable (2 Gruppen) auf eine metrische Variable?
- **Differenzierung zwischen**:
  - t-Test bei unabhängigen Stichproben – Messungen bei zwei Gruppen
  - t-Test bei abhängigen Stichproben – Messungen bei derselben Gruppe (z.B. vorher – nachher)
- **Vorgehen bei der Analyse**:
  1) Ist der p-value <0.05 (<0.01, <0.001)? → Signifikanz?
  2) Wie unterscheiden sich die Mittelwerte?

t-Test: Übungsaufgaben & R-Befehle

Aufgaben:

- Beurteilen Männer und Frauen das Gesamtprogramm von Radiosendern (signifikant) unterschiedlich?
- Beurteilen Männer und Frauen die Musik von Radiosendern (signifikant) unterschiedlich?

Prof. Dr.
Godbersen

R (mosaic) – Key Commands

Get going
install.packages("xyz")
require(xyz) <- starting mosaic, psych, psy, ggplot2, openxlsx, plspm (required for each session)

Recoding, computing, formatting variables & creating new datasets:
Recoding (new) variables:
dataset$new_variable[dataset$old_variable=="XXX"] <- "new_value"
→ Please note: categorial values require quotes ("), numerical values not
Calucalting new variables:
dataset$new_variable <- dataset$variable1 + dataset$variable2
Changing the the variable formats:
dataset$new_variable <- as.numeric(dataset$variable)

General command structure
command(y~x, z)

Frequencies
tally(~variable1, data = dataset)
tally(~variable1, format = "percent", data = dataset)
tally(variable1~variable2, data = dataset)
tally(variable1~variable2, format = "percent", data = dataset)

Median, mean, variance, standard deviation, maximum, minimum
median(~variable, data = dataset) / mean(~variable, data = dataset)
var(~variable, data = dataset) / sd(~variable, data = dataset)
max(~variable, data = dataset) / min(~variable, data = dataset)
favstats(~variable, data = dataset)
→ result: Min, Q1, median, Q3, Max , mean, standard deviation, n, missing values)

Prof. Dr. Hendrik Godbersen: R (mosaic) – Key Commands 1

Prof. Dr.
Godbersen

Chi² test
xchisq.test(variable1~variable2, data = dataset)

t-test
t.test(variable~grouping_variable, data = dataset)

ANOVA
summary(aov(variable~grouping_variable, data = dataset))
→ alternative way:
modelxy <- aov(variable~grouping_variable, data = dataset)
summary(modelxy)

Shapiro-Wilk test
shapiro.test(dataset$variable)

Linear regression
summary(lm(dependent_variable~independent_variable, data = dataset))

Multiple regression
summary(lm(dependent_variable~ind_variable1 + ind_variable2, data = dataset))

Principal Component analysis (package: psych)
dataset_new <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)
colnames(dataset_new) <- c("Item_1", "Item_2")
KMO(dataset_new)
pcaX <- princomp(dataset_new, scores = TRUE, cor = TRUE)
summary(pcaX) plot(pcaX)
principal(dataset_new, nfactors = x, rotate = "varimax")

Cronbach's Alpha (package: psy)
factorX <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)
cronbach(factorX)

Prof. Dr. Hendrik Godbersen: R (mosaic) – Key Commands 2

t-test

t.test(variable~grouping_variable, data = dataset)

Variablen

- Stammsender
- SenderCluster

- Verlaesslicher_Service
- Informative_Nachrichten
- Unterhaltsame_Nachrichten
- Aktuelle_Musik
- Alte_Musik
- Anregende_Musik
- Beruhigende_Musik
- Informative_Moderation
- Unterhaltsame_Moderation
- Sympathische_Stimme
- Anspruchsvolle_Comedy
- Lustige_Comedy
- Spannende_Gewinnspiele
- Attraktive_Preise

- Berichterstattung
- **Musik**
- Moderation
- Comedy
- Gewinnspiele

- **Gesamtprogramm**

- **Geschlecht**
- Alter

- Altersgruppen
- Aktuelle_ Musik_A

t-Test: Umsetzung in R

Inhalt

1 Einleitung

2 Installation & Grundstruktur von R Studio

2.1 Installation von R, R Studio & relevanten Paketen

2.2 Grundstruktur von R Studio

3 R-Befehle & Übungsdaten

3.1 R-Befehle

3.2 Übungsdaten

4 Datenmanagement

4.1 Datenvorbereitung & Laden von Daten

4.2 Daten bearbeiten in R

5 Deskriptive Statistik

5.1 Skalenniveaus

5.2 Häufigkeiten

5.3 Lageparameter & Streuungsmaße

6 Inferenzstatistische Verfahren

6.1 Überblick & Systematisierung der Verfahren

6.2 Chi-Quadrat-Test

6.3 t-Test

6.4 ANOVA

6.5 Shapiro-Wilk-Test

6.6 Wilcoxon-Test

6.7 Korrelation

6.8 Regression

6.9 Hauptkomponentenanalyse

7 Graphiken & Export von Ergebnissen nach Excel

7.1 Graphiken in R

7.2 Export von Ergebnissen nach Excel

ANOVA: Steckbrief

- **Verwendung:**
  - Die Varianzanalyse (*Analysis of Variance, ANOVA*) ist ein parametrisches Verfahren und untersucht, ob sich die Mittelwerte mehrerer (mehr als zwei) unabhängiger Stichproben systematisch unterscheiden.
- **Fragestellung:**
  - Gibt es einen „nicht-zufälligen“ statistischen Unterschied zwischen mehr als zwei Stichproben in Bezug auf ein metrisches Merkmal?
- **Abgrenzung zum t-Test:**
  - Während der t-Test metrische Merkmale von maximal zwei Stichproben auf signifikante Unterschiede prüft, werden bei der Varianzanalyse mehrere Mittelwerte verglichen
- **Beispiel:**

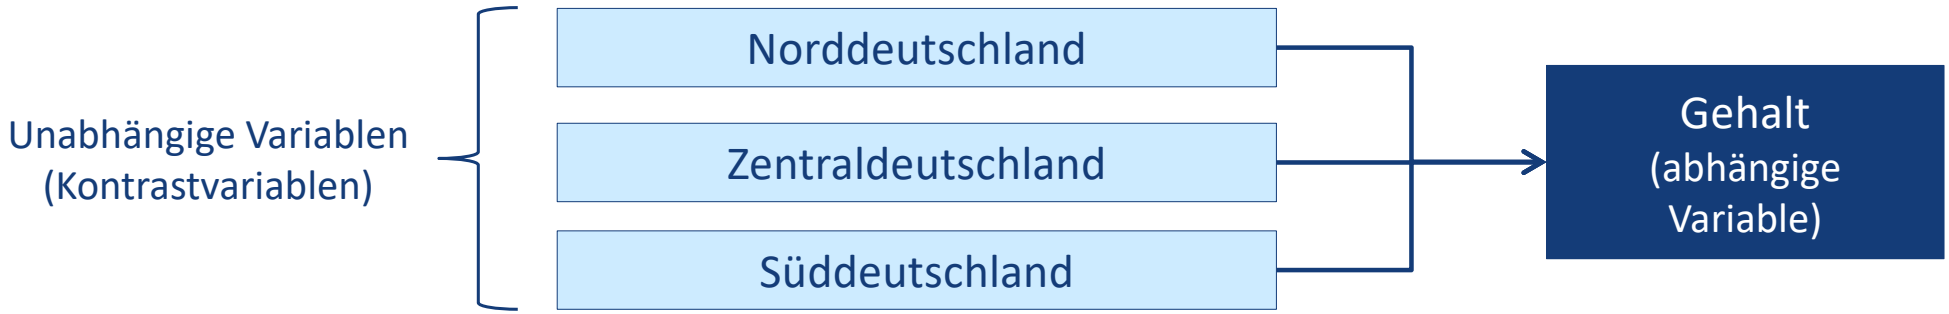

ANOVA: Übungsaufgaben & R-Befehle

Aufgaben:

- Beurteilen die Hörer der verschiedenen SenderCluster das Gesamtprogramm von Radiosendern (signifikant) unterschiedlich?
- Beurteilen die Hörer der verschiedenen SenderCluster die Moderation von Radiosendern (signifikant) unterschiedlich?

Prof. Dr. Godbersen

R (mosaic) – Key Commands

Get going
install.packages("xyz")
require(xyz) <- starting mosaic, psych, psy, ggplot2, openxlsx, plspm (required for each session)

Recoding, computing, formatting variables & creating new datasets:
Recoding (new) variables:
dataset$new_variable[dataset$old_variable=="XXX"] <- "new_value"
→ Please note: categorial values require quotes ("'), numerical values not
Calucalting new variables:
dataset$new_variable <- dataset$variable1 + dataset$variable2
Changing the the variable formats:
dataset$new_variable <- as.numeric(dataset$variable)
→ factor to numeric

command(y~x, z)

Frequencies
tally(~variable1, data = dataset)
tally(~variable1, format = "percent", data = dataset)
tally(variable1~variable2, data = dataset)
tally(variable1~variable2, format = "percent", data = dataset)

Median, mean, variance, standard deviation, maximum, minimum
median(~variable, data = dataset) / mean(~variable, data = dataset)
var(~variable, data = dataset) / sd(~variable, data = dataset)
max(~variable, data = dataset) / min(~variable, data = dataset)
favstats(~variable, data = dataset)
→ result: Min, Q1, median, Q3, Max , mean, standard deviation, n, missing values)

Prof. Dr. Godbersen

Chi² test
xchisq.test(variable1~variable2, data = dataset)

t-test
t.test(variable~grouping_variable, data = dataset)

ANOVA
summary(aov(variable~grouping_variable, data = dataset))
→ alternative way:
modelxy <- aov(variable~grouping_variable, data = dataset)
summary(modelxy)

Shapiro-Wilk test
shapiro.test(dataset$variable)

Mann-Whitney & Wicoxon test

Linear regression
summary(lm(dependent_variable~independent_variable, data = dataset))

Multiple regression
summary(lm(dependent_variable~ind_variable1 + ind_variable2, data = dataset))

Principal Component analysis (package: psych)
dataset_new <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)
colnames(dataset_new) <- c("Item_1", "Item_2")
KMO(dataset_new)
pcaX <- princomp(dataset_new, scores = TRUE, cor = TRUE)
summary(pcaX) plot(pcaX)
principal(dataset_new, nfactors = x, rotate = "varimax")

Cronbach's Alpha (package: psy)
factorX <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)
cronbach(factorX)

Prof. Dr. Hendrik Godbersen: R (mosaic) – Key Commands 1

Prof. Dr. Hendrik Godbersen: R (mosaic) – Key Commands 2

ANOVA

summary(aov(variable~grouping_variable, data = dataset))

Variablen

- Stammsender
- **SenderCluster**

- Verlaesslicher_Service
- Informative_Nachrichten
- Unterhaltsame_Nachrichten
- Aktuelle_Musik
- Alte_Musik
- Anregende_Musik
- Beruhigende_Musik
- Informative_Moderation
- Unterhaltsame_Moderation
- Sympathische_Stimme
- Anspruchsvolle_Comedy
- Lustige_Comedy
- Spannende_Gewinnspiele
- Attraktive_Preise

- Berichterstattung
- Musik
- **Moderation**
- Comedy
- Gewinnspiele

- **Gesamtprogramm**

- Geschlecht
- Alter

- Altersgruppen
- Aktuelle_ Musik_A

ANOVA: Umsetzung in R

Inhalt

1 Einleitung

2 Installation & Grundstruktur von R Studio

2.1 Installation von R, R Studio & relevanten Paketen

2.2 Grundstruktur von R Studio

3 R-Befehle & Übungsdaten

3.1 R-Befehle

3.2 Übungsdaten

4 Datenmanagement

4.1 Datenvorbereitung & Laden von Daten

4.2 Daten bearbeiten in R

5 Deskriptive Statistik

5.1 Skalenniveaus

5.2 Häufigkeiten

5.3 Lageparameter & Streuungsmaße

6 Inferenzstatistische Verfahren

6.1 Überblick & Systematisierung der Verfahren

6.2 Chi-Quadrat-Test

6.3 t-Test

6.4 ANOVA

6.5 Shapiro-Wilk-Test

6.6 Wilcoxon-Test

6.7 Korrelation

6.8 Regression

6.9 Hauptkomponentenanalyse

7 Graphiken & Export von Ergebnissen nach Excel

7.1 Graphiken in R

7.2 Export von Ergebnissen nach Excel

Shapiro-Wilk-Test: Steckbrief

- **Verwendung**:
  - Der Shapiro-Wilk-Test vergleicht die Werte einer Stichprobe mit normalverteilten Werten, um zu überprüfen, ob eine Normalverteilung angenommen werden kann. **Bei kleinen Stichproben (ca. n < 50) ist die Normalverteilung Voraussetzung für die Anwendung des t-Tests**.
- **Fragestellung & Ergebnisinterpretation**:
  - Sind die Werte einer mindestens intervallskalierten Variable normalverteilt?
    - Ist der Test nicht signifikant **(p > .10)**, unterscheidet sich die Verteilung der vorliegenden Stichprobe nicht von einer normalverteilten Stichprobe → **Normalverteilung**
    - Ist der Test signifikant **(p ≤ .10)**, unterscheidet sich die Verteilung der vorliegenden Stichprobe von einer normalverteilten Stichprobe → **keine Normalverteilung**
- **Konsequenz bei fehlender Normalverteilung**:
  - U.a. werden statt des t-Tests Rangverfahren wie Wilcoxon-/Mann-Whitney-Test angewendet
  - Beachte: I.d.R. ist es sinnvoll, nicht nur den Shapiro-Wilk-Test durchzuführen, sondern auch einen Blick auf die (graphische) Verteilung zu werfen.

```
        Shapiro-Wilk normality test

data:  radio$Alter
W = 0.87431, p-value = 3.079e-14
```

Die Daten sind nicht normalverteilt.

Shapiro-Wilk-Test: Übungsaufgaben & R-Befehle

Aufgaben:

- Ist die Variabel Alter normalverteilt?
- Ist die Variabel Gesamtprogramm normalverteilt?

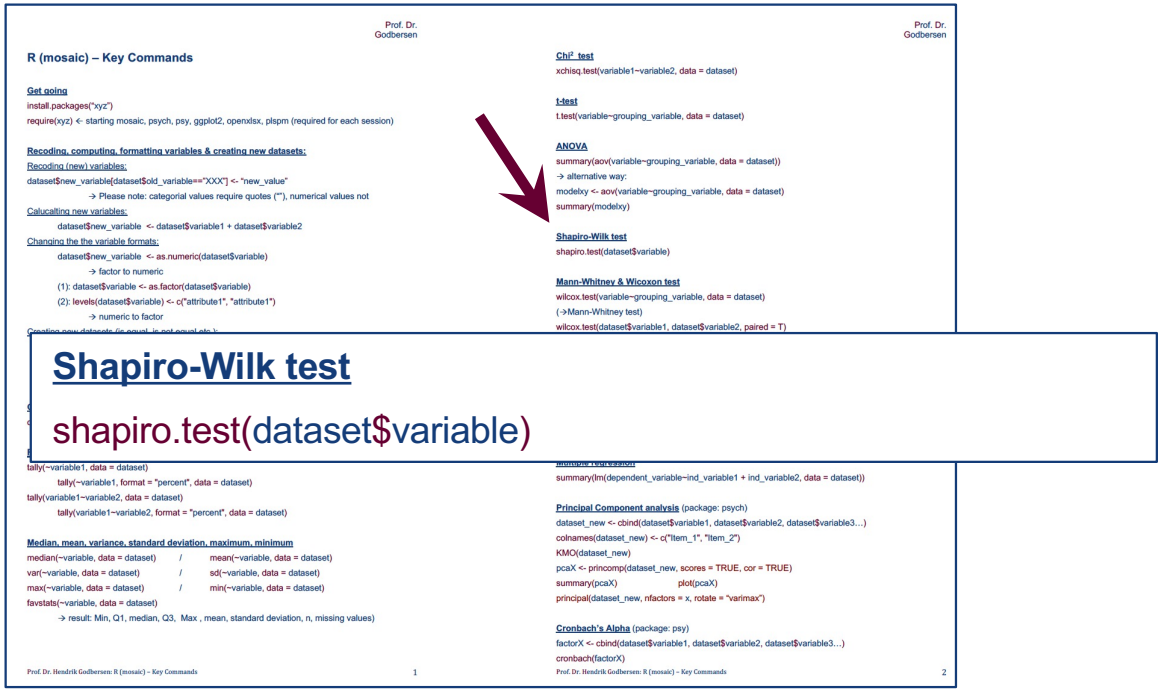

Prof. Dr. Godbersen

R (mosaic) – Key Commands

Get going
install.packages("xyz")
require(xyz) <- starting mosaic, psych, psy, ggplot2, openxlsx, plspm (required for each session)

Recoding, computing, formatting variables & creating new datasets:
Recoding (new) variables:
dataset$new_variable[dataset$old_variable=="XXX"] <- "new_value"
→ Please note: categorial values require quotes ("'), numerical values not
Calucalting new variables:
dataset$new_variable <- dataset$variable1 + dataset$variable2
Changing the the variable formats:
dataset$new_variable <- as.numeric(dataset$variable)
→ factor to numeric
(1): dataset$variable <- as.factor(dataset$variable)
(2): levels(dataset$variable) <- c("attribute1", "attribute1")
→ numeric to factor

tally(~variable1, data = dataset)
tally(~variable1, format = "percent", data = dataset)
tally(variable1~variable2, data = dataset)
tally(variable1~variable2, format = "percent", data = dataset)

Median, mean, variance, standard deviation, maximum, minimum
median(~variable, data = dataset) / mean(~variable, data = dataset)
var(~variable, data = dataset) / sd(~variable, data = dataset)
max(~variable, data = dataset) / min(~variable, data = dataset)
favstats(~variable, data = dataset)
→ result: Min, Q1, median, Q3, Max , mean, standard deviation, n, missing values)

Prof. Dr. Hendrik Godbersen: R (mosaic) – Key Commands 1

Prof. Dr. Godbersen

Chi² test
xchisq.test(variable1~variable2, data = dataset)

t-test
t.test(variable~grouping_variable, data = dataset)

ANOVA
summary(aov(variable~grouping_variable, data = dataset))
→ alternative way:
modelxy <- aov(variable~grouping_variable, data = dataset)
summary(modelxy)

Shapiro-Wilk test
shapiro.test(dataset$variable)

Mann-Whitney & Wicoxon test
wilcox.test(variable~grouping_variable, data = dataset)
(→Mann-Whitney test)
wilcox.test(dataset$variable1, dataset$variable2, paired = T)

summary(lm(dependent_variable~ind_variable1 + ind_variable2, data = dataset))

Principal Component analysis (package: psych)
dataset_new <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)
colnames(dataset_new) <- c("Item_1", "Item_2")
KMO(dataset_new)
pcaX <- princomp(dataset_new, scores = TRUE, cor = TRUE)
summary(pcaX) plot(pcaX)
principal(dataset_new, nfactors = x, rotate = "varimax")

Cronbach's Alpha (package: psy)
factorX <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)
cronbach(factorX)

Prof. Dr. Hendrik Godbersen: R (mosaic) – Key Commands 2

Shapiro-Wilk test

shapiro.test(dataset$variable)

Variablen

- Stammsender
- SenderCluster

- Verlaesslicher_Service
- Informative_Nachrichten
- Unterhaltsame_Nachrichten
- Aktuelle_Musik
- Alte_Musik
- Anregende_Musik
- Beruhigende_Musik
- Informative_Moderation
- Unterhaltsame_Moderation
- Sympathische_Stimme
- Anspruchsvolle_Comedy
- Lustige_Comedy
- Spannende_Gewinnspiele
- Attraktive_Preise

- Berichterstattung
- Musik
- Moderation
- Comedy
- Gewinnspiele

- **Gesamtprogramm**

- Geschlecht
- **Alter**

- Altersgruppen
- Aktuelle_ Musik_A

Shapiro-Wilk-Test: Umsetzung in R

Inhalt

1 Einleitung

2 Installation & Grundstruktur von R Studio

2.1 Installation von R, R Studio & relevanten Paketen

2.2 Grundstruktur von R Studio

3 R-Befehle & Übungsdaten

3.1 R-Befehle

3.2 Übungsdaten

4 Datenmanagement

4.1 Datenvorbereitung & Laden von Daten

4.2 Daten bearbeiten in R

5 Deskriptive Statistik

5.1 Skalenniveaus

5.2 Häufigkeiten

5.3 Lageparameter & Streuungsmaße

6 Inferenzstatistische Verfahren

6.1 Überblick & Systematisierung der Verfahren

6.2 Chi-Quadrat-Test

6.3 t-Test

6.4 ANOVA

6.5 Shapiro-Wilk-Test

6.6 Wilcoxon-Test

6.7 Korrelation

6.8 Regression

6.9 Hauptkomponentenanalyse

7 Graphiken & Export von Ergebnissen nach Excel

7.1 Graphiken in R

7.2 Export von Ergebnissen nach Excel

Wilcoxon-Test: Steckbrief

- **Verwendung**:
  - Der Rangsummen-Test ist ein non-parametrisches Verfahren und vergleicht die *mittleren Rangzahlen* zweier Gruppen. (Es liegt keine Verteilungsannahme vor, u.a. Normalverteilung wurde auf Grund von Shapiro-Wilk-Test abgelehnt)
- **Fragestellung**:
  - Gibt es einen „nicht-zufälligen“ statistischen Unterschied zwischen zwei Gruppen in Bezug auf ein mindestens ordinalskaliertes Merkmal?
- **Beispiel**:

```
        Wilcoxon rank sum test with continuity correction

data:  Gewinnspiele by Geschlecht
W = 7577.5, p-value = 0.005188
alternative hypothesis: true location shift is not equal to 0
```

Die Daten sind nicht normalverteilt.

Wilcoxon-Test: Übungsaufgaben & R-Befehle

Aufgaben:

- Liegt nach dem Wilcoxon-Test ein signifikanter Unterschied zwischen Männern und Frauen bei der Beurteilung des Gesamtprogramms vor?
- Liegt nach dem Wilcoxon-Test ein signifikanter Unterschied zwischen Männern und Frauen bei der Beurteilung der Musik vor?

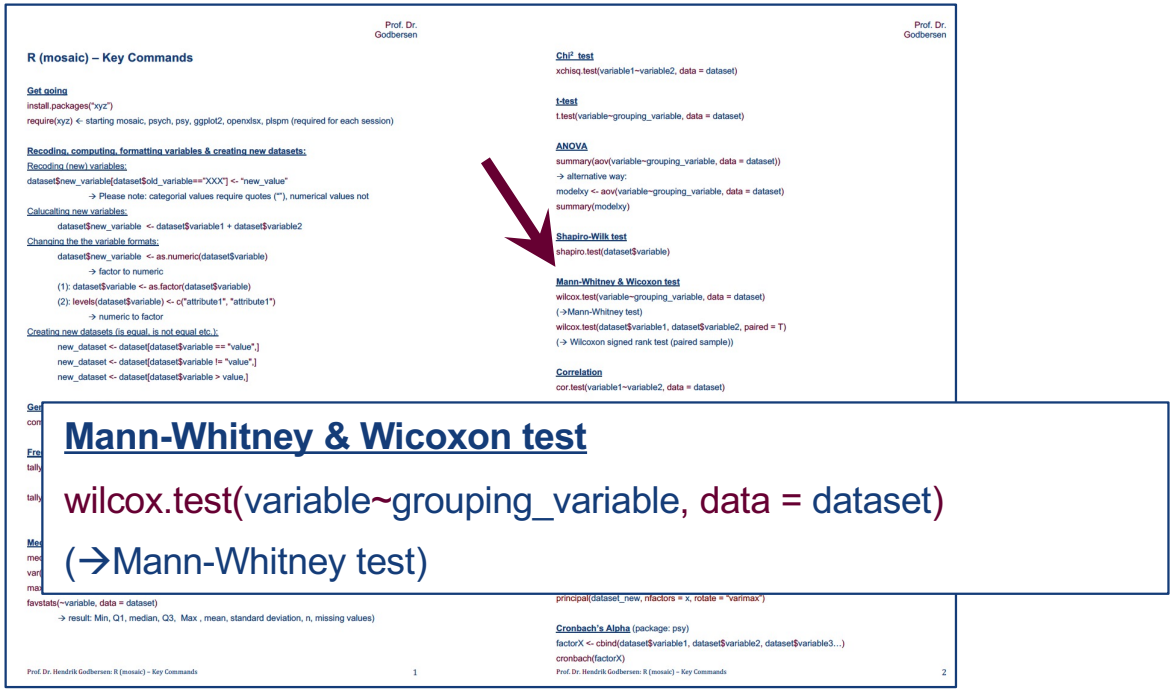

Prof. Dr. Godbersen

R (mosaic) – Key Commands

Get going
install.packages("xyz")
require(xyz) <- starting mosaic, psych, psy, ggplot2, openxlsx, plspm (required for each session)

Recoding, computing, formatting variables & creating new datasets:
Recoding (new) variables:
dataset$new_variable[dataset$old_variable=="XXX"] <- "new_value"
→ Please note: categorial values require quotes ("), numerical values not
Calucalting new variables:
dataset$new_variable <- dataset$variable1 + dataset$variable2
Changing the the variable formats:
dataset$new_variable <- as.numeric(dataset$variable)
→ factor to numeric
(1): dataset$variable <- as.factor(dataset$variable)
(2): levels(dataset$variable) <- c("attribute1", "attribute1")
→ numeric to factor
Creating new datasets (is equal, is not equal etc.):
new_dataset <- dataset[dataset$variable == "value",]
new_dataset <- dataset[dataset$variable != "value",]
new_dataset <- dataset[dataset$variable > value,]

favstats(~variable, data = dataset)
→ result: Min, Q1, median, Q3, Max , mean, standard deviation, n, missing values)

Prof. Dr. Godbersen

Chi² test
xchisq.test(variable1~variable2, data = dataset)

t-test
t.test(variable~grouping_variable, data = dataset)

ANOVA
summary(aov(variable~grouping_variable, data = dataset))
→ alternative way:
modelxy <- aov(variable~grouping_variable, data = dataset)
summary(modelxy)

Shapiro-Wilk test
shapiro.test(dataset$variable)

Mann-Whitney & Wicoxon test
wilcox.test(variable~grouping_variable, data = dataset)
(→Mann-Whitney test)
wilcox.test(dataset$variable1, dataset$variable2, paired = T)
(→ Wilcoxon signed rank test (paired sample))

Correlation
cor.test(variable1~variable2, data = dataset)

principal(dataset_new, nfactors = x, rotate = "varimax")

Cronbach's Alpha (package: psy)
factorX <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)
cronbach(factorX)

Prof. Dr. Hendrik Godbersen: R (mosaic) – Key Commands 1 2

Mann-Whitney & Wicoxon test

wilcox.test(variable~grouping_variable, data = dataset)

(→Mann-Whitney test)

Variablen

- Stammsender
- SenderCluster

- Verlaesslicher_Service
- Informative_Nachrichten
- Unterhaltsame_Nachrichten
- Aktuelle_Musik
- Alte_Musik
- Anregende_Musik
- Beruhigende_Musik
- Informative_Moderation
- Unterhaltsame_Moderation
- Sympathische_Stimme
- Anspruchsvolle_Comedy
- Lustige_Comedy
- Spannende_Gewinnspiele
- Attraktive_Preise

- Berichterstattung
- **Musik**
- Moderation
- Comedy
- Gewinnspiele

- **Gesamtprogramm**

- **Geschlecht**
- Alter

- Altersgruppen
- Aktuelle_ Musik_A

Wilcoxon-Test: Umsetzung in R

Inhalt

1 Einleitung

2 Installation & Grundstruktur von R Studio

2.1 Installation von R, R Studio & relevanten Paketen

2.2 Grundstruktur von R Studio

3 R-Befehle & Übungsdaten

3.1 R-Befehle

3.2 Übungsdaten

4 Datenmanagement

4.1 Datenvorbereitung & Laden von Daten

4.2 Daten bearbeiten in R

5 Deskriptive Statistik

5.1 Skalenniveaus

5.2 Häufigkeiten

5.3 Lageparameter & Streuungsmaße

6 Inferenzstatistische Verfahren

6.1 Überblick & Systematisierung der Verfahren

6.2 Chi-Quadrat-Test

6.3 t-Test

6.4 ANOVA

6.5 Shapiro-Wilk-Test

6.6 Wilcoxon-Test

6.7 Korrelation

6.8 Regression

6.9 Hauptkomponentenanalyse

7 Graphiken & Export von Ergebnissen nach Excel

7.1 Graphiken in R

7.2 Export von Ergebnissen nach Excel

Korrelation: Steckbrief

- **Verwendung**:
  - Die Korrelationsanalyse untersucht den (linearen) Zusammenhang zwischen zwei oder mehr metrischen Variablen.
- **Fragestellung**:
  - Wie stark ist der lineare Zusammenhang zwischen den Variablen – und in welcher Richtung besteht er? → Wird der Wert von Variable A erhöht / gesenkt oder bleibt er gleich, wenn sich der Wert von Variable B ändert?
- **Vorgehen:**
  1) Ist der p-value <0.05 (<0.01, <0.001)? → Signifikanz?
  2) Wie hoch ist der Korrelationskoeffizient?
- **Mögliche Interpretation des Korrelationskoeffizienten**:

$0 < r \leq +1.0$	gleichgerichteter Zusammenhang
$-1.0 \geq r < 0$	entgegengesetzter Zusammenhang

$0.2 < \lvert r \rvert \leq 0.5$	geringe Korrelation
$0.5 < \lvert r \rvert \leq 0.7$	mittlere Korrelation
$0.7 < \lvert r \rvert \leq 1.0$	hohe Korrelation

Korrelation: Steckbrief

- Statistische Erklärung des Korrelationskoeffizienten

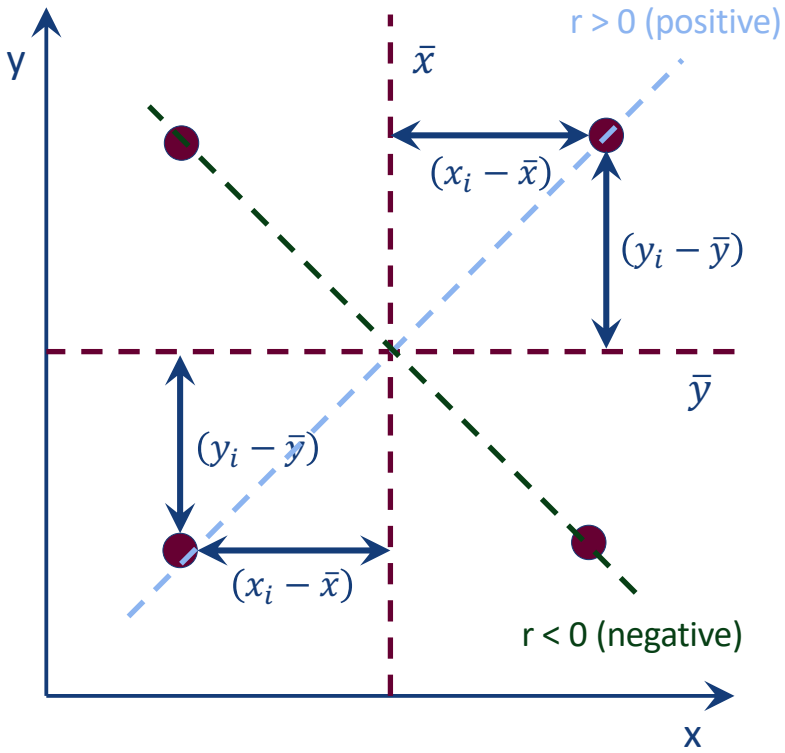

Kovarianz (gemeinsame Streuung zweier Variablen):

$$\text{cov} = \frac{1}{n}\sum_{i=1}^{n}(x_i - \bar{x})(y_i - \bar{y})$$

Varianz (Streuung einer Variablen):

$$\text{var} = \sigma_x = \frac{1}{n}\sum_{i=1}^{n}(x_i - \bar{x})^2$$

Korrelationskoeffizient (Anteil der gemeinsamen Streuung zweier Variablen an der gesamten Streuung):

$$r = \frac{\frac{1}{n}\sum_{i=1}^{n}(x_i - \bar{x})(y_i - \bar{y})}{var_x * var_y}$$

Korrelation: Übungsaufgaben & R-Befehle

Aufgaben:

- Gibt es einen nicht-zufälligen Zusammenhang zwischen der Beurteilung der Musik und der Moderation?
- Gibt es einen nicht-zufälligen Zusammenhang zwischen der Beurteilung von Comedy und Gewinnspielen?

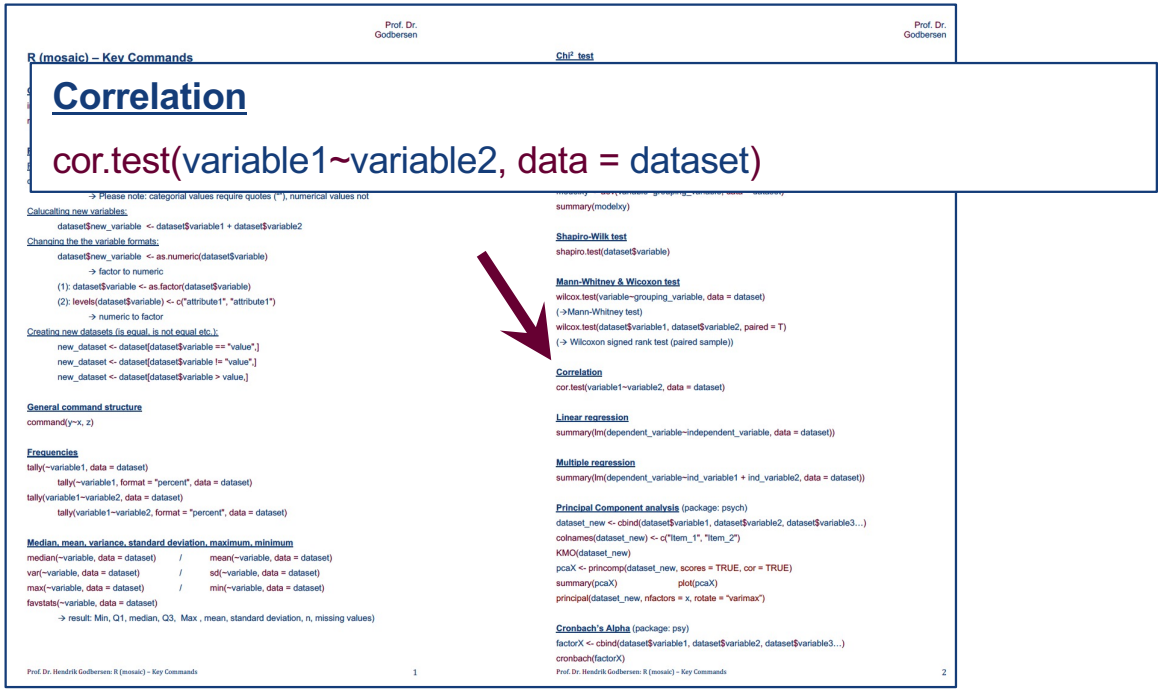

Prof. Dr. Godbersen

R (mosaic) – Key Commands

→ Please note: categorial values require quotes ("''"), numerical values not

Calucalting new variables:

dataset$new_variable <- dataset$variable1 + dataset$variable2

Changing the the variable formats:

dataset$new_variable <- as.numeric(dataset$variable)

→ factor to numeric

(1): dataset$variable <- as.factor(dataset$variable)

(2): levels(dataset$variable) <- c("attribute1", "attribute1")

→ numeric to factor

Creating new datasets (is equal, is not equal etc.):

new_dataset <- dataset[dataset$variable == "value",]

new_dataset <- dataset[dataset$variable != "value",]

new_dataset <- dataset[dataset$variable > value,]

General command structure

command(y~x, z)

Frequencies

tally(~variable1, data = dataset)

tally(~variable1, format = "percent", data = dataset)

tally(variable1~variable2, data = dataset)

tally(variable1~variable2, format = "percent", data = dataset)

Median, mean, variance, standard deviation, maximum, minimum

median(~variable, data = dataset) / mean(~variable, data = dataset)

var(~variable, data = dataset) / sd(~variable, data = dataset)

max(~variable, data = dataset) / min(~variable, data = dataset)

favstats(~variable, data = dataset)

→ result: Min, Q1, median, Q3, Max , mean, standard deviation, n, missing values)

Prof. Dr. Hendrik Godbersen: R (mosaic) – Key Commands 1

Prof. Dr. Godbersen

Chi² test

summary(modelxy)

Shapiro-Wilk test

shapiro.test(dataset$variable)

Mann-Whitney & Wicoxon test

wilcox.test(variable~grouping_variable, data = dataset)

(→Mann-Whitney test)

wilcox.test(dataset$variable1, dataset$variable2, paired = T)

(→ Wilcoxon signed rank test (paired sample))

Correlation

cor.test(variable1~variable2, data = dataset)

Linear regression

summary(lm(dependent_variable~independent_variable, data = dataset))

Multiple regression

summary(lm(dependent_variable~ind_variable1 + ind_variable2, data = dataset))

Principal Component analysis (package: psych)

dataset_new <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)

colnames(dataset_new) <- c("Item_1", "Item_2")

KMO(dataset_new)

pcaX <- princomp(dataset_new, scores = TRUE, cor = TRUE)

summary(pcaX) plot(pcaX)

principal(dataset_new, nfactors = x, rotate = "varimax")

Cronbach's Alpha (package: psy)

factorX <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)

cronbach(factorX)

Prof. Dr. Hendrik Godbersen: R (mosaic) – Key Commands 2

Correlation

cor.test(variable1~variable2, data = dataset)

Variablen

- Stammsender
- SenderCluster

- Verlaesslicher_Service
- Informative_Nachrichten
- Unterhaltsame_Nachrichten
- Aktuelle_Musik
- Alte_Musik
- Anregende_Musik
- Beruhigende_Musik
- Informative_Moderation
- Unterhaltsame_Moderation
- Sympathische_Stimme
- Anspruchsvolle_Comedy
- Lustige_Comedy
- Spannende_Gewinnspiele
- Attraktive_Preise

- Berichterstattung
- **Musik**
- **Moderation**
- **Comedy**
- **Gewinnspiele**

- Gesamtprogramm

- Geschlecht
- Alter

- Altersgruppen
- Aktuelle_ Musik_A

Korrelation: Umsetzung in R

Inhalt

1 Einleitung

2 Installation & Grundstruktur von R Studio

2.1 Installation von R, R Studio & relevanten Paketen

2.2 Grundstruktur von R Studio

3 R-Befehle & Übungsdaten

3.1 R-Befehle

3.2 Übungsdaten

4 Datenmanagement

4.1 Datenvorbereitung & Laden von Daten

4.2 Daten bearbeiten in R

5 Deskriptive Statistik

5.1 Skalenniveaus

5.2 Häufigkeiten

5.3 Lageparameter & Streuungsmaße

6 Inferenzstatistische Verfahren

6.1 Überblick & Systematisierung der Verfahren

6.2 Chi-Quadrat-Test

6.3 t-Test

6.4 ANOVA

6.5 Shapiro-Wilk-Test

6.6 Wilcoxon-Test

6.7 Korrelation

6.8 Regression

6.9 Hauptkomponentenanalyse

7 Graphiken & Export von Ergebnissen nach Excel

7.1 Graphiken in R

7.2 Export von Ergebnissen nach Excel

Regression: Steckbrief

- **Verwendung:**
  - Die lineare Regression untersucht den linearen Einfluss einer metrischen Variable (Einfachregression) oder mehrerer metrischer Variablen (Multiple Regression) auf eine abhängige metrische Variable.
- **Fragestellung:**
  - Inwieweit kann der Wert einer abhängigen Variablen durch die Werte einer (Einfachregression) oder mehrere (Multiple Regression) unabhängigen Variablen erklärt werden?
- **Regressionsgerade (Ergebnis der Analyse):**
  - **y = a + b * x**
  - y: Abhängige Variable („Wirkung“)
  - x: Unabhängige Variable („Ursache“)
  - a: y-Achsenabschnitt
  - b: Regressionskoeffizient („um wieviel steigt y, wenn x sich um eine Einheit erhöht“)

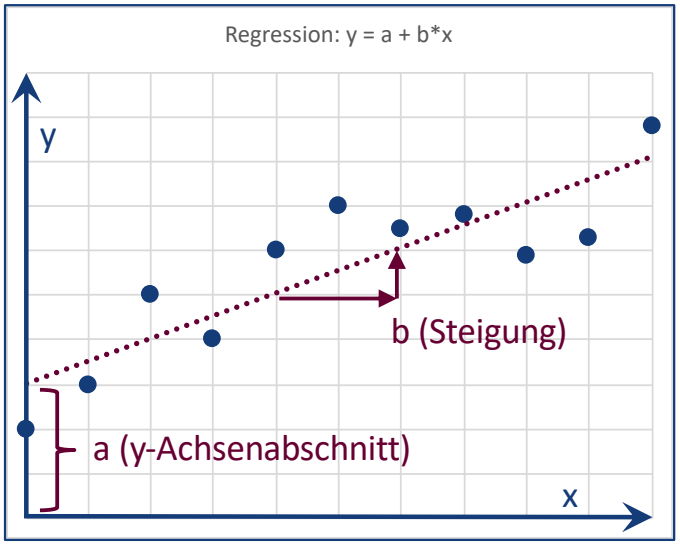

- **Statistische Analyse („im Hintergrund“):**
  - Im Rahmen der Regressionsanalyse wird die Gerade ermittelt, bei der die quadrierten Abweichungen der gemessen Werte von der Geraden am geringsten ist (Methode der kleinsten Quadrate)

Regression: Steckbrief

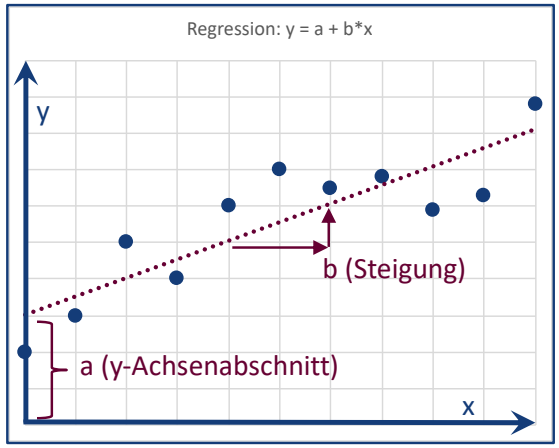

- **Vorgehen**:
  1) Sind die p-values <0.05 (<0.01, <0.001)?
     - Liegt ein signifikanter Einfluss von x_i auf y vor (p-values)?
  2) Wie hoch sind die Regressionskoeffizienten (b)?
     - Wie stark ist der Einfluss von x_i auf y?
  3) Welchen Wert hat das Bestimmtheitsmaß (R^2)?
     - Wie hoch ist der Erklärungsgehalt des Modells?
     - R^2 = Anteil der Varianz der abhängigen Variable, den die unabhängigen Variablen erklären

```
Call:
lm(formula = Gesamtprogramm ~ Moderation, data = radio)

Residuals:
    Min      1Q  Median      3Q     Max
-48.169  -6.168   1.293   8.611  50.672

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) 49.32790    2.26833   21.75   <2e-16 ***
Moderation   0.42062    0.03162   13.30   <2e-16 ***
---
Signif. codes:  0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

Residual standard error: 13.36 on 273 degrees of freedom
Multiple R-squared:  0.3933,	Adjusted R-squared:  0.3911
F-statistic:   177 on 1 and 273 DF,  p-value: < 2.2e-16
```

1) p-value
2) Regressionskoeffizient
3) Bestimmtheitsmaß (R^2)

Regression: Übungsaufgaben & R-Befehle

Aufgaben:

- Welchen Einfluss hat die Musik auf das Gesamtprogramm?
- Welchen Einfluss hat die Comedy auf das Gesamtprogramm?
- Welchen Einfluss haben die fünf Programmelemente auf das Gesamtprogramm?

Linear regression

summary(lm(dependent_variable~independent_variable, data = dataset))

Multiple regression

summary(lm(dependent_variable~ind_variable1 + ind_variable2, data = dataset))

```
new_dataset <- dataset[dataset$variable > value,]

General command structure
command(y~x, z)

Frequencies
tally(~variable1, data = dataset)
        tally(~variable1, format = "percent", data = dataset)
tally(variable1~variable2, data = dataset)
        tally(variable1~variable2, format = "percent", data = dataset)

Median, mean, variance, standard deviation, maximum, minimum
median(~variable, data = dataset)   /   mean(~variable, data = dataset)
var(~variable, data = dataset)      /   sd(~variable, data = dataset)
max(~variable, data = dataset)      /   min(~variable, data = dataset)
favstats(~variable, data = dataset)
        → result: Min, Q1, median, Q3,  Max , mean, standard deviation, n, missing values)
```

Prof. Dr. Hendrik Godbersen: R (mosaic) – Key Commands 1

```
Correlation
cor.test(variable1~variable2, data = dataset)

Linear regression
summary(lm(dependent_variable~independent_variable, data = dataset))

Multiple regression
summary(lm(dependent_variable~ind_variable1 + ind_variable2, data = dataset))

Principal Component analysis (package: psych)
dataset_new <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)
colnames(dataset_new) <- c("Item_1", "Item_2")
KMO(dataset_new)
pcaX <- princomp(dataset_new, scores = TRUE, cor = TRUE)
summary(pcaX)                plot(pcaX)
principal(dataset_new, nfactors = x, rotate = "varimax")

Cronbach's Alpha (package: psy)
factorX <- cbind(dataset$variable1, dataset$variable2, dataset$variable3…)
cronbach(factorX)
```

Prof. Dr. Hendrik Godbersen: R (mosaic) – Key Commands 2

Variablen

- Stammsender
- SenderCluster

- Verlaesslicher_Service
- Informative_Nachrichten
- Unterhaltsame_Nachrichten
- Aktuelle_Musik
- Alte_Musik
- Anregende_Musik
- Beruhigende_Musik
- Informative_Moderation
- Unterhaltsame_Moderation
- Sympathische_Stimme
- Anspruchsvolle_Comedy
- Lustige_Comedy
- Spannende_Gewinnspiele
- Attraktive_Preise

- **Berichterstattung**
- **Musik**
- **Moderation**
- **Comedy**
- **Gewinnspiele**

- **Gesamtprogramm**

- Geschlecht
- Alter

- Altersgruppen
- Aktuelle_ Musik_A

Inhalt

1 Einleitung

2 Installation & Grundstruktur von R Studio

2.1 Installation von R, R Studio & relevanten Paketen

2.2 Grundstruktur von R Studio

3 R-Befehle & Übungsdaten

3.1 R-Befehle

3.2 Übungsdaten

4 Datenmanagement

4.1 Datenvorbereitung & Laden von Daten

4.2 Daten bearbeiten in R

5 Deskriptive Statistik

5.1 Skalenniveaus

5.2 Häufigkeiten

5.3 Lageparameter & Streuungsmaße

6 Inferenzstatistische Verfahren

6.1 Überblick & Systematisierung der Verfahren

6.2 Chi-Quadrat-Test

6.3 t-Test

6.4 ANOVA

6.5 Shapiro-Wilk-Test

6.6 Wilcoxon-Test

6.7 Korrelation

6.8 Regression

6.9 Hauptkomponentenanalyse

7 Graphiken & Export von Ergebnissen nach Excel

7.1 Graphiken in R

7.2 Export von Ergebnissen nach Excel

Hauptkomponentenanalyse (& Cronbachs α): Steckbrief

- **Anwendung**:
  - Die Hauptkomponentenanalyse wird verwendet, um Fragen/Variablen/Indikatoren zu wenigen Dimensionen zusammenzufassen.
- **Fragestellung**:
  - Können multidimensionale metrische Daten auf wenige wichtige Hauptkomponenten verdichtet werden?
- **Grundidee**:
  - Die Items einer Komponente korrelieren hoch miteinander.
  - Die Items unterschiedlicher Komponenten korrelieren nicht hoch miteinander.

Indikatoren (Items) der Mitarbeiterbindung	Ladungen (>0,5) der Items auf die Hauptkomponenten der Bindung				Zuverlässigkeit der Skalen		
	affektiv	kognitiv	normativ	vertraglich	Cronbachs Alpha	Composite Reliability	AVE
Ich empfinde es als angenehm, bei meinem Arbeitgeber zu arbeiten.	0,76						
Ich fühle mich mit meinem Arbeitgeber persönlich verbunden.	0,81						
Ich fände es persönlich schade, wenn die Beschäftigung bei meinem Arbeitgeber beendet würde.	0,82						0,62
Ich kann mich mit meinem Arbeitgeber und den Produkten/Dienstleistungen identifizieren.	0,81						
Meine persönlichen Kontakte zu meinem Arbeitsumfeld sind für mich von Bedeutung.	0,61						
In gewisser Weise bindet mich der für einen Wechsel benötigte Zeitaufwand an meinem Arbeitgeber.		0,79					
Ich bin auf meinen Arbeitgeber angewiesen, weil es zurzeit keine gleichwertigen Alternativen am Markt gibt.		0,[illegible]					[illegible]3
Ich empfinde eine Bindung an meinen Arbeitgeber, weil bei einem Wechsel der von mir investierte Aufwand an Wert verlieren würde.		0,[illegible]					
Ich fühle mich an meinen Arbeitgeber gebunden, weil ein Wechsel mit Wechselkosten einhergehen würde.		0,67					
Es wäre nicht fair, die Beziehung zu meinem Arbeitgeber aufzukündigen, weil er sich stets um mich als Arbeitnehmer bemüht hat.			0,63				
Aufgrund der langen Beziehung mit meinem Arbeitgeber fühle ich mich zu einer gewissen Rücksichtnahme verpflichtet.			0,76		0,80	0,83	0,55
Ich fühle mich in der Angestelltenbeziehung mit dem Arbeitgeber zur Fairness verpflichtet.			0,81				
Moralische Verpflichtungen gegenüber dem Arbeitgeber spielen für mich auch eine Rolle.			0,82				
Ich bin vertraglich an meinen Arbeitgeber gebunden.				0,93	1	1	1

hohe Korrelation

geringe Korrelation

Quelle: Gansser, O. & Godbersen, H. (2017). Mitarbeiterbindung durch Betriebliches Gesundheitsmanagement. Ergebnisse einer empirischen Studie und Leitfaden für die Praxis. zfo Zeitschrift Führung + Organisation, Jg. 86 (2), 108-116.

Hauptkomponentenanalyse (& Cronbachs α): Steckbrief

- Vorgehen
  0) Vorbereiten der Datenbasis (neuer Datensatz)
  1) Prüfung, ob eine Hauptkomponentenanalyse durchgeführt werden kann/soll mittels KMO (Kaiser-Meyer-Olkin-Test (misst den Anteil der Varianz zwischen Variablen, der auf gemeinsame Varianz zurückzuführen ist)
  2) Bestimmung der Anzahl der Komponenten anhand der Eigenwerte
     - ➢ Auswahl: So viele Komponenten wie Eigenwerte > 1
  3) Bestimmung der Faktorladungen (Korrelation eines Items mit einer Komponente) & Zuordnung der Items zu Komponenten
     - ➢ Voraussetzung: Ladung > 0.5
     - ➢ Entscheidung: Zuordnung des Items zu der Komponente, auf der es am höchsten lädt
  4) Interpretation der Komponenten
  5) Testen der einzelnen Komponenten mittels Cronbachs α
     (Reliabilität; durchschnittliche Korrelation aller Split-half-tests))

KMO – Interpretation:
- 0.00 to 0.49 - unacceptable
- 0.50 to 0.59 - miserable
- **0.60** to 0.69 - mediocre
- **0.70** to 0.79 - middling
- 0.80 to 0.89 - meritorious
- 0.90 to 1.00 - marvellous

```
Kaiser-Meyer-Olkin factor adequacy
Call: KMO(r = pca_radio_data)
Overall MSA =  0.85
```

```
Importance of components:
                          Comp.1    Comp.2    Comp.3    Comp.4    Comp.5    Comp.6    Comp.7    Comp.8    Comp.9
Standard deviation     2.359856 1.2124941 1.16061942 1.00739666 0.98060991 0.84432456 0.78977668 0.73846855 0.63632144
Proportion of Variance 0.397780 0.1050101 0.09621696 0.07248915 0.06868541 0.05092028 0.04455337 0.03895256 0.02892178
Cumulative Proportion  0.397780 0.5027901 0.59900708 0.67149623 0.74018164 0.79110192 0.83565530 0.87460785 0.90352964
                          Comp.10    Comp.11    Comp.12    Comp.13    Comp.
Standard deviation     0.63167541 0.51744946 0.50533062 0.48631269 0.438
Proportion of Variance 0.02850099 0.01912528 0.01823993 0.01689286 0.013
Cumulative Proportion  0.93203063 0.95115591 0.96939584 0.98628870 1.000
```

4 Komponenten

Zuordnung der Items

```
Principal Components Analysis
Call: principal(r = pca_radio_data, nfactors = 4, rotate =  varimax )
Standardized loadings (pattern matrix) based upon correlation matrix
                          RC1   RC4   RC3   RC2   h2   u2 com
Verlaesslicher_Service    0.16  0.78  0.18 -0.10 0.67 0.33 1.2
Informative_Nachrichten   0.12  0.90  0.03  0.02 0.83 0.17 1.0
Unterhaltsame_Nachrichten 0.48  0.47  0.04  0.35 0.58 0.42 2.8
Aktuelle_Musik            0.19 -0.02 -0.02  0.77 0.62 0.38 1.1
Alte_Musik                0.29  0.16  0.65 -0.12 0.55 0.45 1.
```

```
> cronbach(comp_Unterhaltung)
$sample.size
[1] 275

$number.of.items
[1] 5

$alpha
[1] 0.8511712
```

Cronbachs α – akzeptierbare Werte:
- **> 0.6** (“weiches” Kriterium)
- **> 0.7** (“hartes” Kriterium)

Hauptkomponentenanalyse (& Cronbachs α): Übungsaufgaben & R-Befehle

Aufgaben:

- Zu welchen Komponenten lassen sich die Programmeigenschaften zusammenfassen? („Wie können aus den Programmeigenschaften neue übergeordnete Variablen gebildet werden?“)
- Wie ist die Reliability der neuen Komponenten zu beurteilen?

Principal Component analysis (package: psych)

```
dataset_new <- cbind(dataset$variable1, dataset$variable2…)
colnames(dataset_new) <- c("Item_1", "Item_2")
KMO(dataset_new)
pcaX <- princomp(dataset_new, scores = TRUE, cor = TRUE)
summary(pcaX)                    plot(pcaX)
principal(dataset_new, nfactors = x, rotate = “varimax”)
```

Cronbach’s Alpha (package: psy)

```
factorX <- cbind(dataset$variable1, dataset$variable2…)
cronbach(factorX)
```

Variablen

- Stammsender
- SenderCluster

- **Verlaesslicher_Service**
- **Informative_Nachrichten**
- **Unterhaltsame_Nachrichten**
- **Aktuelle_Musik**
- **Alte_Musik**
- **Anregende_Musik**
- **Beruhigende_Musik**
- **Informative_Moderation**
- **Unterhaltsame_Moderation**
- **Sympathische_Stimme**
- **Anspruchsvolle_Comedy**
- **Lustige_Comedy**
- **Spannende_Gewinnspiele**
- **Attraktive_Preise**

- Berichterstattung
- Musik
- Moderation
- Comedy
- Gewinnspiele

- Gesamtprogramm

- Geschlecht
- Alter

- Altersgruppen
- Aktuelle_ Musik_A

Hauptkomponentenanalyse (& Cronbachs α): Umsetzung in R

Inhalt

1 Einleitung

2 Installation & Grundstruktur von R Studio

- 2.1 Installation von R, R Studio & relevanten Paketen
- 2.2 Grundstruktur von R Studio

3 R-Befehle & Übungsdaten

- 3.1 R-Befehle
- 3.2 Übungsdaten

4 Datenmanagement

- 4.1 Datenvorbereitung & Laden von Daten
- 4.2 Daten bearbeiten in R

5 Deskriptive Statistik

- 5.1 Skalenniveaus
- 5.2 Häufigkeiten
- 5.3 Lageparameter & Streuungsmaße

6 Inferenzstatistische Verfahren

- 6.1 Überblick & Systematisierung der Verfahren
- 6.2 Chi-Quadrat-Test
- 6.3 t-Test
- 6.4 ANOVA
- 6.5 Shapiro-Wilk-Test
- 6.6 Wilcoxon-Test
- 6.7 Korrelation
- 6.8 Regression
- 6.9 Hauptkomponentenanalyse

7 Graphiken & Export von Ergebnissen nach Excel

- 7.1 Graphiken in R
- 7.2 Export von Ergebnissen nach Excel

Graphiken in R: Ergebnisse

Prof. Dr.
Godbersen

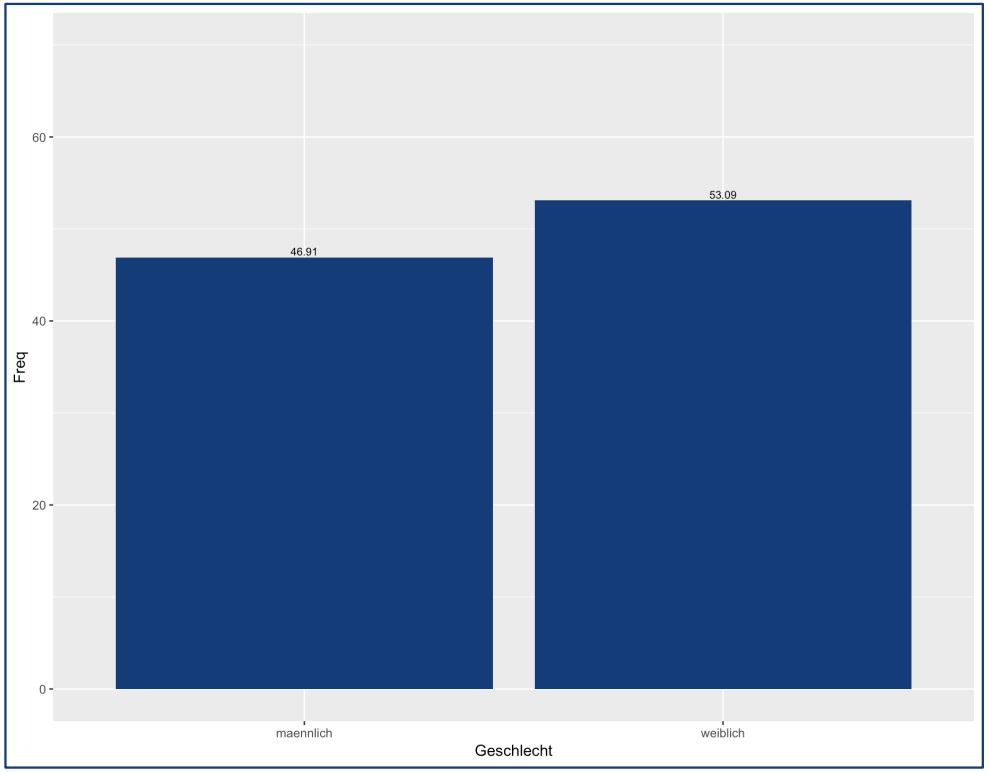

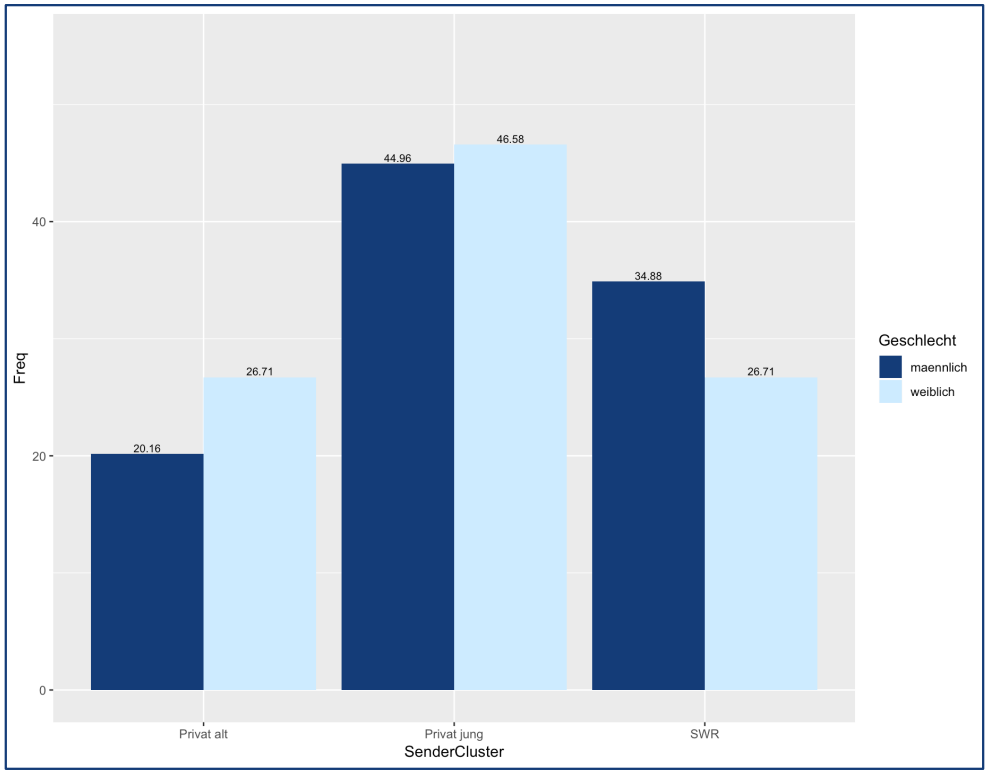

Graphiken in R: Übungsaufgaben & R-Befehle

Aufgaben:

- Erstellen Sie ein Säulendiagramm, das die relativen Häufigkeiten (%) der Variable Geschlecht widergibt.
- Erstellen Sie ein Säulendiagramm, dass die relativen Häufigkeiten (%) der Variable SenderCluster in Abhängigkeit vom Geschlecht widergibt.

Variablen

- Stammsender
- **SenderCluster**
- Verlaesslicher_Service
- Informative_Nachrichten
- Berichterstattung
- Musik
- Moderation
- Comedy
- Gewinnspiele
- Gesamtprogramm
- **Geschlecht**
- Alter
- Altersgruppen
- Aktuelle_ Musik_A

Bar graph – frequencies with 1 variable

```
table <- tally(~variable, format = "proportion",data = dataset)
frame <- as.data.frame(table)
View(frame)
ggplot(frame, aes(variable, Freq)) + geom_bar(position = "dodge", stat = "identity", fill = "#143C78") +
scale_y_continuous(limits = c(min, max)) + geom_text(aes(label = sprintf("%0.2f", frame$Freq)), position =
position_dodge(width = 0.9), vjust = -0.25, colour = "black", size = 2.7)
```

Bar graph – frequencies with 2 variables

```
table <- tally(variable_1~variable_2, format= "proportion",data = dataset)
frame <- as.data.frame(table)
View(frame)
ggplot(frame, aes(variable_1, Freq, fill = variable_2)) + geom_bar(position = "dodge", stat = "identity") +
scale_fill_manual(values = c("#143C78", "#CDEBFF")) + scale_y_continuous(limits = c(min, max)) + geom_text(aes(label =
sprintf("%0.2f", frame$Freq)), position = position_dodge(width = 0.9), vjust = -0.25, colour = "black", size = 2.7)
```

Inhalt

1 Einleitung

2 Installation & Grundstruktur von R Studio

- 2.1 Installation von R, R Studio & relevanten Paketen
- 2.2 Grundstruktur von R Studio

3 R-Befehle & Übungsdaten

- 3.1 R-Befehle
- 3.2 Übungsdaten

4 Datenmanagement

- 4.1 Datenvorbereitung & Laden von Daten
- 4.2 Daten bearbeiten in R

5 Deskriptive Statistik

- 5.1 Skalenniveaus
- 5.2 Häufigkeiten
- 5.3 Lageparameter & Streuungsmaße

6 Inferenzstatistische Verfahren

- 6.1 Überblick & Systematisierung der Verfahren
- 6.2 Chi-Quadrat-Test
- 6.3 t-Test
- 6.4 ANOVA
- 6.5 Shapiro-Wilk-Test
- 6.6 Wilcoxon-Test
- 6.7 Korrelation
- 6.8 Regression
- 6.9 Hauptkomponentenanalyse

7 Graphiken & Export von Ergebnissen nach Excel

- 7.1 Graphiken in R
- 7.2 Export von Ergebnissen nach Excel

Export von Ergebnissen nach Excel: Ergebnisse

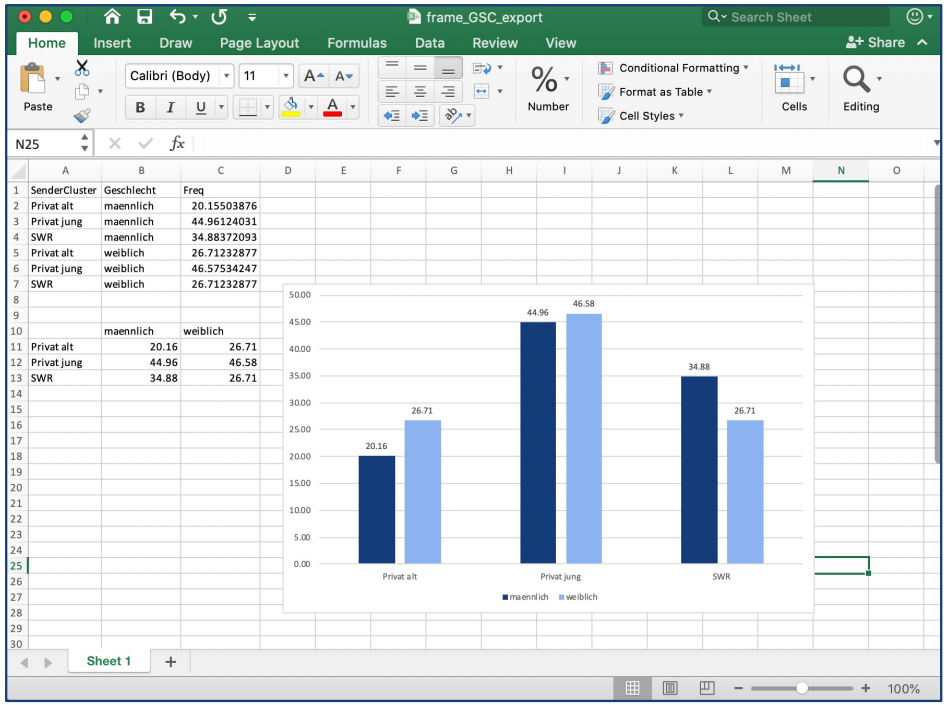

SenderCluster	Geschlecht	Freq
Privat alt	maennlich	20.15503876
Privat jung	maennlich	44.96124031
SWR	maennlich	34.88372093
Privat alt	weiblich	26.71232877
Privat jung	weiblich	46.57534247
SWR	weiblich	26.71232877

	maennlich	weiblich
Privat alt	20.16	26.71
Privat jung	44.96	46.58
SWR	34.88	26.71

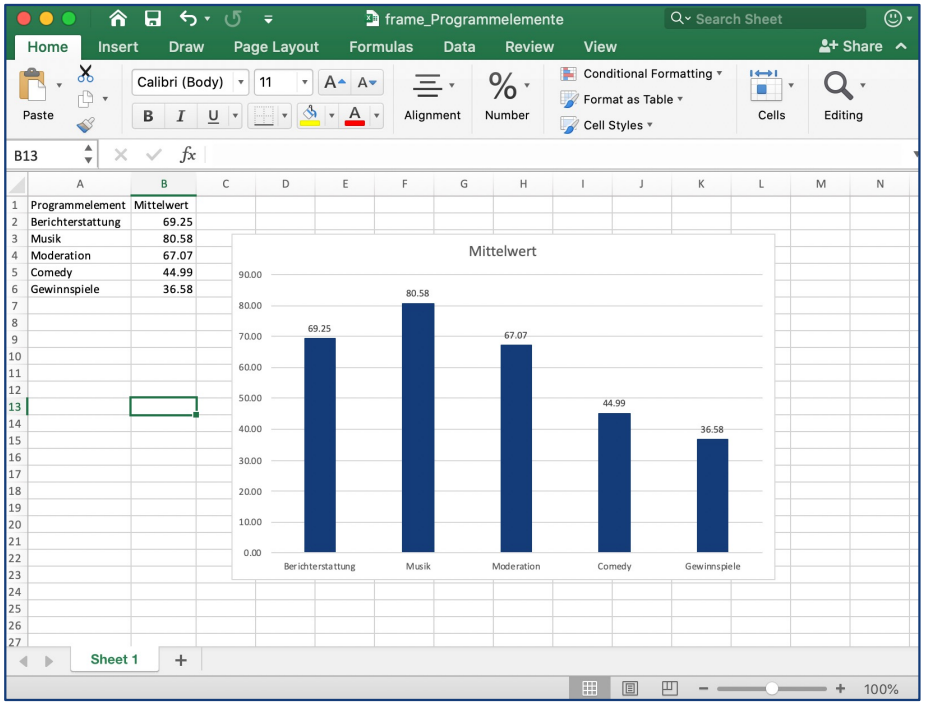

Programmelement	Mittelwert
Berichterstattung	69.25
Musik	80.58
Moderation	67.07
Comedy	44.99
Gewinnspiele	36.58

Export von Ergebnissen nach Excel: Übungsaufgaben & R-Befehle

Prof. Dr.
Godbersen

Aufgaben:

- Exportieren Sie die relativen Häufigkeiten (%) der Variable SenderCluster in Abhängigkeit vom Geschlecht nach Excel.
- Exportieren Sie die Mittelwerte der Bewertungen der Programmelemente nach Excel.

Export R results to Excel (package: openxlsx)

(1.1) Preparing frequencies

```
frame <- data.frame(tally(variable_1~variable_1, data = dataset))
```

(1.2) Preparing mean, median etc.

```
frame <- data.frame(new_variable_name_1 =
c(mean(~variable_1, data = dataset), mean(~variable_2, data =
dataset)), new_variable_name_2 = c(mean(~variable_3, data =
dataset), mean(~varaible_4, data = dataset)))
```

(2) Export to Excel

```
write.xlsx(frame, "Desktop/R_operations/name.xlsx", asTable =
FALSE)
```

→ Please note: The name of the R frame & the directory / name of the xlsx-file have to be adjusted

Variablen

- Stammsender
- **SenderCluster**

- Verlaesslicher_Service
- Informative_Nachrichten
- Unterhaltsame_Nachrichten
- Aktuelle_Musik
- Alte_Musik
- Anregende_Musik
- Beruhigende_Musik
- Informative_Moderation
- Unterhaltsame_Moderation
- Sympathische_Stimme
- Anspruchsvolle_Comedy
- Lustige_Comedy
- Spannende_Gewinnspiele
- Attraktive_Preise

- **Berichterstattung**
- **Musik**
- **Moderation**
- **Comedy**
- **Gewinnspiele**

- Gesamtprogramm

- **Geschlecht**
- Alter

- Altersgruppen
- Aktuelle_ Musik_A

Prof. Dr. Hendrik Godbersen

www.godbersen.online